

Kasvuston biomassan määrittäminen multispektrikamerakuvien ja 3D-mallinnuksen avulla

Mikael Änäckälä
Maisterintutkielma
Helsingin yliopisto
Maataloustieteiden osasto
Agroteknologia
2020

Tiedekunta/Osasto Fakultet/Sektion – Faculty Maatalous-metsätieteellinen tiedekunta		Laitos/Institution– Department Maataloustieteiden osasto
Tekijä/Författare – Author Mikael Änäckälä		
Työn nimi / Arbetets titel – Title Kasvuston biomassan määrittäminen multispektrikamerakuvien ja 3D-mallinnuksen avulla		
Oppiaine /Läroämne – Subject Agroteknologia		
Työn laji/Arbetets art – Level Maisterintutkielma	Aika/Datum – Month and year 5/2020	Sivumäärä/ Sidoantal – Number of pages 65
<p>Tiivistelmä/Referat – Abstract</p> <p>Dronejen määrä on kasvanut niin yksityis- kuin yrityskäytössä. Myös maataloudessa ollaan kiinnostuneita droneista, sillä niitä käyttäen on helppo ja nopea tarkkailla suuria peltoaloja. Lisäksi automaattiset lentotehtävät ovat helppoja toteuttaa. Dronekuvaukset antavat laajemman kuvauksen koko pellosta, kuin mitä pellon reunasta voidaan nähdä. Ilmakuvat pelloista helpottavat jatkotoimenpiteiden suunnittelua, kuten esimerkiksi pellon ruiskutustarpeen arvioimista tai lannoituskartan tekemistä. Dronekuvauksia voidaan myös käyttää kasvuston biomassojen arvioimiseen. Tällöin voidaan tarkkailla kasvuston kehittymistä kasvukauden aikana lohko-kohtaisesti.</p> <p>Tämän tutkimuksen tavoitteena oli selvittää, kuinka multispektrikameran kuvia ja 3D-mallia voidaan hyödyntää kasvien tarkkailussa. Kasvustosta mitattavia ominaisuuksia olivat kasvien maanpäällinen biomassa, lehtivihreäpitoisuus ja lehtialaindeksi. Tutkimuksessa oli 8 eri kasvia/lannoitustasoa.</p> <p>Tässä tutkimuksessa käytettiin multispektrikameraa ja tavallista RGB-kameraa kasvuston ominaisuuksien määrittämiseen. Multispektrikameran avulla voitiin määrittää kasvuston heijastusarvoja, jotka kuvasivat sitä, kuinka paljon kasvit heijastivat auringon säteilyä takaisin. Multispektrikamera mittasi heijastusarvoja viideltä eri aallonpituusalueelta (sininen, vihreä, punainen, red edge ja NIR), joiden avulla laskettiin NDVI -kasvillisuusindeksi. Näitä heijastusarvoja ja indeksejä verrattiin kasvuston kuiva-ainemassaan, lehtialaindeksiin ja lehtivihreäpitoisuuteen. RGB-kameran ottamista kuvista luotiin kasvustosta 3D-malli, josta laskettiin kasvuston tilavuus. Kasvuston tilavuuksia verrattaisiin sen biomassoihin ja lehtialaindeksiin arvoihin. Kuvista lasketun ja kasvustosta määritettyjen muuttujien välisen riippuvuuden tarkasteluun käytettiin lineaarista regressioanalyysiä.</p> <p>Multispektrikuvista määritetyt muuttujat selittivät näiden tulosten mukaan hieman heikommin kasvuston kuiva-ainemassaa ja lehtialaindeksiä kuin RGB-kameran kuvista määritetyt 3D-mallit. Multispektrikameran kuvaamasta aineistosta voimakkain määritetty riippuvuus oli härkäpavun lehtialaindeksiin ja NDVI:n välillä ($R^2 = 0,85$). Multispektrikameran heijastusarvo-/indeksiaineistoa käyttäen määritetyt selityssasteet olivat pieniä: kasvuston kuiva-ainemassa oli keskimäärin 0,15, lehtivihreäpitoisuus 0,14 ja lehtialaindeksi 0,21. 3D-mallinnuksen korkein selityssaste oli kauran kuiva-ainemassan ja siitä mitattujen tilavuuksien välillä ($R^2 = 0,91$). Keskimäärin riippuvuuden selityssaste oli 0,69 tarkasteltaessa kasvien kuiva-ainemassoja ja 3D-mallien tilavuuksia. Kasvien lehtialaindeksiin ja 3D-mallien välisen riippuvuuden keskimääräinen selityssaste oli 0,57.</p> <p>Näiden tulosten perusteella multispektrikameran datoista NDVI-indeksi soveltui parhaiten kasvuston kuiva-ainemassan, lehtialaindeksiin ja lehtivihreäpitoisuuden määrittämiseen. Eri heijastusalueiden/NDVI-indeksiin ja kasvien ominaisuuksien välisissä riippuvuuksissa on kuitenkin eroja eri kasvien välillä. 3D-mallit tuottivat voimakkaampia riippuvuuksia kasvuston biomassan ja lehtialaindeksiin arvioimiseen kuin multispektrikuvista määritetyt suureet. Aineiston analysointi laskentamenetelmillä, jotka hyödyntävät useampien aallonpituusalueiden arvoja sekä niistä laskettuja indeksejä, olisi todennäköisesti ollut nyt käytettyä lineaarista regressiota tehokkaampi menetelmä aineiston analysoinnissa.</p> <p>Ulkoisten tekijöiden aiheuttamien häiriöiden poistaminen multispektrikameran kuvista oli hyvin haasteellista. Varsinkin kuivan maan heijastusarvot poikkesivat kasvuston heijastusarvoista. Jatkotutkimuksissa pitäisi kehittää erilaisia kasvillisuusindeksejä, jotka vähentävät ympäristön aiheuttamaa häiriötä. Tämän lisäksi tulisi kehittää aineistojen käsittelyä siten, että hyödynnetään useita aallonpituusalueita ja kasvillisuusindeksejä kasvuston ominaisuuksien ja kuvista mitattujen muuttujien välisen riippuvuuden määrittämiseksi. Sen lisäksi tulisi tutkia kasvilajikohtaisia kuvantamistekniikoita, sillä eri kasveilla on erilaiset heijastusarvot.</p>		
Avainsanat – Nyckelord – Keywords Drone, UAV, 3D-malli, Multispektrikamera, RGB-kamera		
Säilytyspaikka – Förvaringställe – Where deposited Helsingin yliopiston digitaalinen arkisto HELDA		
Muita tietoja – Övriga uppgifter – Additional information Työtä ohjasi professori Laura Alakukku ja apulaisprofessori Antti Lajunen		

Tiedekunta/Osasto Fakultet/Sektion – Faculty Faculty of Agriculture and Forestry		Laitos/Institution– Department Department of Agricultural Sciences	
Tekijä/Författare – Author Mikael Änäkälä			
Työn nimi / Arbetets titel – Title Determination of crop biomass using multispectral camera and 3D modeling			
Oppiaine /Läroämne – Subject Agrotechnology			
Työn laji/Arbetets art – Level M.Sc. Thesis		Aika/Datum – Month and year 5/2020	Sivumäärä/ Sidoantal – Number of pages 65
<p>Tiivistelmä/Referat – Abstract</p> <p>The number of drones has increased in both the private and corporate sectors. There is also an interest in the use of drones in agriculture since by using them the large fields can be monitored easily. Automatic flight systems of drones are simple to use. More accurate overview of the field can be got by utilizing the drones than by making observations from the side of the field. With aerial photographs the measures for the field can be planned further. For example, based on the photos pesticide spraying or fertilize spreading can be planned for the field. Drones can also be used to estimate crop biomasses. With drones the development of the crops is possible to observe as a timeseries during the growing season.</p> <p>The aim of this study was to explore the use of multispectral images and 3D models in crop monitoring. Crop leaf area index (LAI), biomass and chlorophyll content were measured. There were 8 different plants/fertilization levels in this study.</p> <p>In this study, a multispectral camera and a RGB-camera were used to estimate crops features. With a multispectral camera the reflectance values of the vegetation, which described how much of the incoming sun radiation was reflected back from the vegetation, were able to determine. The multispectral camera had five spectral bands (blue, green, red, red edge and NIR). Based on these bands NDVI vegetation index was calculated. The reflectance values and vegetation indices were compared to the dry matter mass, LAI, and chlorophyll content determinations of the vegetation. From the images of the RGB-camera 3D-models were created to calculate crop volumes. Calculated volumes were compared to crop dry matter mass and LAI measurements. Linear regression analysis was used to examine the relationship between the variables calculated from the images and the parameters determined from the crops on the field.</p> <p>According to these results, the variables determined from the multispectral images explained the dry matter mass and leaf area index of the crop slightly less than the 3D-models determined from the RGB images. The strongest determined dependence of the data recorded by the multispectral camera was between the faba bean LAI and NDVI ($R^2 = 0,85$). The relationship between the reflection/index data of multispectral camera and crop parameter was weak: average coefficient of determination for dry matter mass of the crop was 0.15, for chlorophyll content 0.14, and for LAI 0,21. The highest coefficient of determination for 3D model of crop volume was between the dry matter mass of oats ($R^2 = 0.91$). The mean coefficient of dependence was 0.69 for the relationship between the plant dry matter masses and 3D model volumes. The mean coefficient of determination for the relationship between the leaf area index of plants and the 3D model volumes was 0.57.</p> <p>Based on these results, from the multispectral camera data, the NDVI index was best suited to determine the crops dry matter mass, leaf area index, and chlorophyll content. However, there were differences in the dependencies between different spectral bands/NDVI index and plant properties determined from different crops. 3D models produced stronger dependences for estimating crop dry matter mass and leaf area index than the quantities determined from multispectral images. Analyzing the data with more sophisticated calculation methods utilizing the values of several spectral bands and the indices in the same time would probably have been a more efficient method to analyzing the data than the current used linear regression used in this study.</p> <p>Removing errors, caused by external factors, from multispectral images was found to be very difficult. Especially reflectance values of dry soil differed clearly from vegetations values. Further studies are needed to develop vegetation indices that can reduce errors caused by external factors. In addition, data processing of images should be developed to utilize multiple spectral bands and vegetation indices to determine the relationship between crop characteristics and variables measured from images. In addition, different plant species imaging techniques should be investigated, as different plants have different reflection values.</p>			
Avainsanat – Nyckelord – Keywords Drone, UAV, 3D, Multispectralcamera, RGB-camera			
Säilytyspaikka – Förvaringställe – Where deposited University of Helsinki Digital Archives HELDA			
Muita tietoja – Övriga uppgifter – Additional information The thesis was supervised by Professor Laura Alakukku and assistant professor Antti Lajunen			

Sisällys

Lyhenteet ja käsitteet	6
1 Johdanto	8
2. Katsaus kirjallisuuteen.....	10
2.1 Dronet ilma-aluksina ja niitä koskeva lainsäädäntö.....	10
2.2 Auringon säteilyn ominaisuudet ja sen mittaaminen	11
2.3 Dronejen kamerat	12
2.4 Kasvillisuusindeksit	14
2.5 Kasvuston 3D-mallinnus	17
2.6 Dronekuvausten soveltaminen maataloudessa	19
3. Tutkimuksen tavoitteet.....	21
4. Aineisto ja menetelmät.....	22
4.1 Tutkimusalueen esittely.....	22
4.2 Koevuonna kenttäkokeesta tehdyt mittaukset	24
4.2.1 Lehtivihreän mittaaminen	25
4.2.2 Lehtialaindeksin mittaaminen	25
4.2.3 Lämpötilan, sademäärän ja säteilyn mittaaminen	26
4.3 Ilmakuvaukset	26
4.3.1 Dronet ja kamerat.....	26
4.3.2 Automaattiset lentotehtävät ja kuvausajat.....	28
4.4 Multispektrikameran kuvien käsittely	30
4.5 3D-mallien käsittely.....	32
4.6 Dronekuvauksien tulosten vertailu kasvuston ominaisuuksiin.....	33
4.7 Kasvukausi ja kuvausolosuhteet	35
4.8 Auringon säteilyn voimakkuus	36
5. Tulokset.....	38
5.1 Multispektrikameran heijastus- ja indeksikartat	38
5.2 Heijastusarvojen ja kasvuston välinen korrelaatio	42
5.2.1 Kasvustonäytteiden ja heijastusarvojen välinen korrelaatio	42
5.2.2 Koko koeruudun ja heijastusarvojen välinen korrelaatio	43
5.3 3D-mallinnus.....	47
6. Tulosten tarkastelu	50
6.1 Kasvuston tunnistaminen multispektrikuvista.....	50
6.2 Kasvuston biomassan arviointi dronekuvien perusteella	50

6.3 Kasvuston LAI ja lehtivihreäpitoisuuden arviointi dronekuvien perusteella	53
6.4 Multispektrikameran ja 3D-mallien vertailu	53
7. Johtopäätökset.....	55
8. Kiitokset	56
Lähteet	56
Liite 1. Yksittäisten näytteiden heijastusarvojen ja kuiva-ainemassojen aineistosta lasketut tilastoarvot	62
Liite 2. Yksittäisten näytteiden heijastusarvojen ja lehtivihreäpitoisuuksien aineistosta lasketut tilastoarvot	62
Liite 3. Koko koeruudun heijastusarvojen ja kuiva-ainemassojen aineistosta lasketut tilastoarvot.....	63
Liite 4. Koko koeruudun heijastusarvojen ja lehtivihreäpitoisuuksien aineistosta lasketut tilastoarvot.....	64
Liite 5. Koko koeruudun heijastusarvojen ja lehtialaindeksien aineistosta lasketut tilastoarvot	64
Liite 6. 3D-mallien tilavuuden ja kuiva-ainemassojen aineistosta lasketut tilastoarvot	65
Liite 7. 3D-mallien tilavuuden ja lehtialaindeksien aineistosta lasketut tilastoarvot.....	65

Lyhenteet ja käsitteet

Drone	Drone on yleisnimitys miehittämättömille laitteille, joilla voi kulkea ilmassa, vedessä ja maalla.
ExG	Excess green index on kasvillisuusindeksi, jonka laskeamiseen tarvitaan sinisen, punaisen ja vihreän värin aallonpituusalueita.
GPS	Eli Global Positioning System on sateliittipaikannusjärjestelmä, jolla voidaan määrittää esimerkiksi dronen tarkka sijainti
Hyperspektrikamera	Hyperspektrikameralla voidaan mitata, kuinka suuri osa auringosta tulevasta säteilystä heijastuu kuvattavasta kohteesta kameran linssiin. Hyperspektrikameralla voidaan mitata säteilyä 1–1000 aallonpituusalueelta.
Kauko-ohjattu ilma-alus	Lentotyössä käytettävä drone
LAI	Lehtialaindeksi (Leaf Area Index)
Lennokki	Harrastus- tai urheilutoimintaan käytettävä drone
Multispektrikamera	Multispektrikameralla voidaan mitata, kuinka suuri osa auringosta tulevasta säteilystä heijastuu kuvattavasta kohteesta kameran linssiin. Multispektrikamera voi mitata säteilyä alle 10:ltä aallonpituusalueelta.
NDVI	Normalisoitu kasvillisuusindeksi (Normalized Difference Vegetation Index)
NIR	Lähi-infrapuna (Near infrared)
Ortomosaiikkikuva	Yhdistelemällä useampia kuvia toisiinsa ja tekemällä niihin geometrisia korjauksia, saadaan luotua ortomosaiikkikuva

PAR	PAR-anturi (Photosynthetically Active Radiation) mittaa kasvien fotosynteesille sopivan säteilyn intensiteettiä (400–700 nm).
PYR	Pyranometri on auringon säteilyä mittaava anturi. Anturi voi mitata säteilyä väliltä 360 – 1120 nm.
Red edge	Aallonpituusalue välillä 712-722 nm
RGB-kamera	RGB-kamera ottaa kuvia punaisen, vihreän ja sinisen värin aallonpituusalueelta
SARVI	Kasvillisuusindeksi (Soil adjusted and atmospherically resistant vegetation index), joka ottaa huomioon maaperän sekä ilmakehän aiheuttaman häiriön heijastusarvojen mittaamisessa.
UAV	Miehittämätön ilma-alus (Unmanned Aerial Vechile) on yleisnimitys droneille ja muille miehittämättömille ilma-aluksille

1 Johdanto

Dronet ja niiden kantamat kamerat ovat kätevä työkalu peltojen kuvauksissa (Näsi ym. 2018, Viljanen ym. 2018, Peña ym. 2013). Niitä on käytetty muun muassa rikkakasvien tunnistamiseen ja luomaan pellosto kartoja, joissa näkyvät rikkakasvien sijainnit ja niiden levinneisyys (Peña ym. 2013). Kasvien typpipitoisuutta on pyritty määrittämään hyperspektrikameran heijastusarvojen perusteella (Fitzgeralda ym. 2010, Näsi ym. 2018). Droneja on myös käytetty aiemmissa tutkimuksissa eri kasvien biomassojen määrittämiseen multispektri- ja hyperspektrikameroiden kuvista (Näsi ym. 2018, Viljanen ym. 2018). Tällä tavalla voidaan arvioida peltolohkojen satojen suuruuksia ja suunnitella esimerkiksi lisälannoituksen tarvetta lohkomittakaavassa.

Droneihin voidaan asentaa erilaisia kameroita. Esimerkiksi multispektri- tai hyperspektrikameralla voidaan mitata kasvustosta heijastuvan säteilyn määrä (Jhan ym. 2017). Näistä heijastusarvoista voidaan edelleen laskea erilaisia kasvillisuusindeksejä (Huete ym. 1994, Fitzgeralda ym. 2010). Esimerkiksi NDVI eli Normalized Difference Vegetation Index on hyvin yleisesti käytetty kasvillisuusindeksi, jolla kuvataan kasvillisuuden terveystilaa (Rouse 1974). Sen lisäksi kasvillisuusindekseillä pyritään vähentämään ympäristön aiheuttamaa häiriötä kuvattaessa kasvustoja (Huete ym. 1994). Hueten ym. (1994) tutkimuksessa käytettiin SARVI (Soil Adjusted and Atmospherically Resistant Vegetation Index) nimistä kasvillisuusindeksiä, joka ottaa huomioon maaperän ja ilmassa olevien aerosolien aiheuttaman häiriön kuvissa. Indeksien laskukaavassa käytetään kertoimia sekä sinisen ja punaisen aallonpituusalueen heijastusarvoja, joilla pyritään vähentämään ulkoisten tekijöiden aiheuttamaa häiriötä.

Dronella otettujen kuvien käsittelyyn liittyy haasteita. Maa voi aiheuttaa häiriötä kuvissa, sillä sen heijastusarvot poikkeavat kasvuston arvoista (MicrolImages 2012). Sen lisäksi, maan kosteus vaikuttaa heijastuvuuden arvoihin, sillä kuivan maan heijastusarvot ovat korkeammat kuin kostealla maalla (MicrolImages 2012, Weidonga 2001). Ilmassa olevat pienhiukkaset voivat aiheuttaa häiriötä kuvissa absorboimalla sekä uudelleen heijastamalla kasvustosta heijastunutta säteilyä (Huete ym. 1994, Guo ym. 2019). Ilmakehän aiheuttama häiriö ei välttämättä näy dronen ottamissa kuvissa, mutta satelliittien ottamiin kuviin sillä on todettu olevan vaikutusta (Guo ym. 2019).

Peltojen kuvaamiseen tarjotaan myös satelliittipalveluja, joiden kuvista voidaan arvioida peltojen lannoitustarvetta (Yara 2019). Tosin satelliittikuvien tarkkuus on noin 10 x 10 metriä, kun taas dronella voidaan päästä huomattavasti tarkempaan resoluutioon (Kaivosoja 2018). Esimerkiksi 50 metrin korkeudelta kuvattuna multispektrikameran tarkkuus voi olla hieman yli 3 x 3 cm (MicaSense 2015). Dronekuvauksen etuna on myös se, että pilvisyys ei estä kuvien ottamista toisin kuin satelliiteilla.

Dronejen lisääntyessä on myös niiden käyttöä koskeva laki tiukentunut ja uudistunut jatkuvasti. Dronejen lennättämiseen liittyvistä määräyksistä huolehtii Suomessa Traficom. Droneja koskeva lainsäädäntö on muuttunut viimeksi 7.12.2018 OPS M1-32 määräyksellä. Tässä määräyksessä kerrotaan muun muassa kuinka korkealla dronella voidaan lentää ja kuinka dronea tulisi käyttää väkijoukkojen lähetyvillä. Dronella lentäminen voidaan jakaa kahteen kategoriaan eli harrastekäyttöön tai ammattimaiseen käyttöön. Molempiin kategorioihin liittyy tarkempia määräyksiä (Traficom 2018).

Tämän tutkimuksen tavoitteena oli selvittää, kuinka multispektrikameran kuvien ja 3D-mallintamisen avulla voidaan määrittää kasvuston maanpäällinen biomassaa. Tutkimuksessa tutkittiin myös kuinka edellä mainitut mittausmenetelmät soveltuvat eri kasveille ja kuinka ne poikkeavat toisistaan tarkkuudeltaan.

2. Katsaus kirjallisuuteen

Seuraavissa luvuissa käsitellään dronen määritelmää ja siihen liittyvää lainsäädäntöä. Sen lisäksi käydään läpi multispektrikameran toimintaa ja kuinka 3D-malleja luodaan ilmakehän aineistosta. Kappaleessa esitellään myös, millaisia dronokuvauksiin liittyviä tutkimuksia on tehty ja kuinka niitä voidaan soveltaa maataloudessa. Tavoitteena on luoda teoreettinen viitekehys työn kokeelliselle osalle.

2.1 Dronet ilma-aluksina ja niitä koskeva lainsäädäntö

Traficom julkaisee dronejen lennättämiseen liittyviä määräyksiä ja viimeisin näistä astui voimaan 7.12.2018. Dronet voidaan luokitella lennokeiksi tai kauko-ohjattaviksi ilma-aluksiksi niiden käyttötarkoituksen perusteella (Kuva 1). Kauko-ohjattavaksi ilma-alukseksi lasketaan alus, joka on miehittämätön ja sitä käytetään erilaisiin lentotöihin. Lennokiksi lasketaan myös alus, joka on miehittämätön, mutta jota käytetään harraste- tai urheilutarkoitukseen (Trafi 2018).



Kuva 1. Dronet luokitellaan käyttötarkoituksen perusteella joko lennokeiksi tai kauko-ohjattaviksi ilma-aluksiksi. Kuvassa kauko-ohjattava ilma-alus DJI Phantom 4 Advance, jota käytettiin tämän tutkimuksen koeruutujen kuvaamiseen 3D-malleja varten. Kuva Mikael Änäkkälä 2018.

Lennokkien lennättämiseen liittyy tiettyjä asetuksia. Traficom (2018) mukaan lennättämisestä aiheutuvien vaarojen tulee olla ihmisille ja omaisuudelle mahdollisimman pieniä. Lennättämisestä aiheutuvan melun tulee olla mahdollisimman pientä eikä lennokin kokonaismassa saa ylittää 25 kg. Lennokista pitää myös löytyä käyttäjän nimi ja yhteystiedot. Näköyhteys lennokkiin tulee aina säilyttää lennon aikana. Maksimi lentokorkeus lennokille on 150 metriä poikkeusalueita lukuun ottamatta. Lentokenttien tai radiovyöhykkeiden lähellä lennättäminen on paljon tarkempaa ja lentoihin tulee kysyä erikseen lupaa.


Kauko-ohjatulla ilma-aluksella lainsäädäntö on hieman tarkempaa lennokkiin verrattuna. Kauko-ohjatun ilma-aluksen lentäjän tulee ilmoittaa Liikenteen turvallisuusvirastolle tiedot käyttäjästä ja ilma-alukseen liittyvät tekniset perustiedot. Sen lisäksi tulee ilmoittaa toiminnan laatu ja taajuus. Lisäksi tulee kertoa, mikäli toimintaa harjoitetaan tiheästi asutettujen asutuskeskusten tai väkijoukkojen päällä. Lennosta vastaavan henkilön tulee olla vähintään 18-vuotias. Lennoista tulisi rekisteröidä päivämäärä, lähtö- ja alustupaikka, ilma-aluksen päällikkö, aluksen tiedot ja lentotehtävän tarkoitus. Lentojen tiedot tulisi säilyttää vähintään kahden vuoden ajan. Kauko-ohjattavaa ilma-alusta koskevat samat lentokorkeusasetukset kuin lennokeilla (Trafi 2018).

Dronen lennättämiseen astuu voimaan uusia asetuksia 1.7.2020. Traficomin hallitsemalla Droneinfo (2020) sivustolla on ilmoitettu tarkemmin dronejen lennättämiseen liittyviä määräyksiä. Uusissa määräyksissä droneja ei enää jaeta harrastus ja ammattikäyttöön, vaan dronejen lennättäminen jaetaan joko avoimeen tai erityiseen kategoriaan. Sen lisäksi dronejen lennättäjien tulee tehdä verkkoteoriakoe ja tarvittaessa lisäteoriakokeita, voidakseen lennättää droneja.

2.2 Auringon säteilyn ominaisuudet ja sen mittaaminen

Mittaamalla auringon säteilyn määrää voidaan laskea, kuinka paljon kasvukauden aikana on ollut fotosynteesille sopivaa säteilyä (Apogee Instruments 2019a ja 2019b). Säteilyantureita tarvitaan myös multispektrikameran kuvien ottamiseen. Multispektrikameraan on liitetty säteilyanturi, joka mittaa auringosta tulevan säteilyn voimakkuutta eri aallonpituusalueilta (Kuva 2). Tätä arvoa tarvitaan laskettaessa kasvuston heijastusarvoja (Micasense 2015). Myös lehtialaindeksin mittaamiseen voidaan käyttää säteilyantureita. Lehtialaindeksimittarissa on kaksi säteilyanturia, joista ensimmäinen mittaa kasvuston yläpuolelle tulevan säteilyn

voimakkuutta. Toinen antureista mittaa kasvuston maan tasalle tulevan säteilyn voimakkuutta. Näiden edellä mainittujen arvojen perusteella ja kasvikohtaisilla kertoimilla voidaan määrittää kasvuston lehtialaindeksi (Apogee Instruments 2006).



Kuva 2. Kuvassa on esitetty eri värien aallonpituusalueet (400–1100 nm) ja Micasense Rededge 3 multispektrikameran viisi aluetta, joilta kamera ottaa kuvia. Alue 1 on sininen (475 nm), alue 2 vihreä (560 nm), alue 3 punainen (668 nm), alue 4 Red edge (717 nm) ja alue 5 lähi-infrapun (NIR eli Near-infrared, 840 nm) aallonpituusalue. Muokattu lähteistä Jensen (2013) ja Micasense (2015).


Auringon säteilyn voimakkuutta voidaan mitata muun muassa PYR ja PAR antureilla. PAR (Photosynthetic Active Radiation) anturilla voidaan mitata kasvien fotosynteesille sopivaa säteilyä. Tämän kaltaiseksi säteilyksi lasketaan säteily, jonka aallonpituus on välillä 400–700 nm. PAR anturien mittaussyksikkö on $\mu\text{mol}/(\text{m}^2\text{s})$ ja ne ilmoittavat yleensä 400–700 nm aallonpituusalueella tulevan säteilyn (Apogee Instruments 2019a ja 2019b).

PYR (Pyranometer) sensori mittaa säteilyä isommalta alueelta kuin mitä PAR sensori. Esimerkiksi tässä tutkimuksessa käytetty Apogeen sensori mittaa 360–1100 nm alueelta tulevaa auringonsäteilyä. Mittausyksikkönä laite ilmoittaa W/m^2 (Apogee Instruments 2019a).

2.3 Dronejen kamerat

Droneissa voidaan käyttää tavallisia RGB (Red-Green-Blue) -kameroita, multispektri- ja hyperspektrikameroita. Hyperspektrikameralla voidaan mitata useampaa aallonpituusaluetta kuin kahdella muulla kameralla. Esimerkiksi Senopin HSC-2 hyperspektrikameralla voidaan ottaa kuvia 1000 eri aallonpituusalueelta (Senop 2020). Multispektrikameroilla on yleensä alle 10 aluetta. Tässä tutkimuk-

sessä käytettiin Micasense Rededge 3 multispektrikameraa, joka ottaa kuvia viideltä eri aallonpituusalueelta (Kuvat 2 ja 3). Tavallisella RGB-kameralla voidaan ottaa kuvia kolmelta eri aallonpituusalueelta. RGB-kamerat ovat huomattavasti edullisempia kuin multi- ja hyperspektrikamerat (Mapir 2020).



Kuva 3. Kuvassa on tutkimuksessa käytetty Micasense Rededge 3 multispektrikamera. Kameralle on rakennettu oma vakain, jotta kuvat olisivat otettu vaakatasossa. Kuvassa kamera on kiinni vakaimessa. Kuva Mikael Änäkkälä 2020.

Kameroiden tärkeimpiä ominaisuuksia ovat muun muassa resoluutio ja aallonpituusalueiden lukumäärä. Mitä suurempi resoluutio kamerassa on, sitä pienempiä kohteita kuvista voidaan tunnistaa (Micasense 2015, Jhan ym. 2017). Suurempi resoluutio mahdollista korkeamman lentokorkeuden, jolloin saadaan lennettyä suurempi ala yhden lennon aikana. Kameroiden aallonpituusalueiden lukumäärä on myös tärkeä ominaisuus. Käyttämällä useampaa aluetta, saadaan kerättyä enemmän dataa, jota voidaan käyttää multilineaarisessa regressioanalyysissä tai neuroverkkoanalyysissä (Näsi ym. 2018, Maimaitijiang ym. 2020). Kameroihin on tärkeää liittää GPS-moduuli, joka kuvien ottohetkellä tallentaa jokaisen kuvan paikkakoordinaatit (Micasense 2018). Tämä helpottaa kuvien jälkikäsittelyä (Pix4D 2017). Kameran paino on tärkeä ominaisuus, sillä se vaikuttaa dronen

lentoaikaan. Mitä painavampi kone on, sitä lyhyempi on lentoaika. Taulukossa 1 on esitetty kolme erilaista kameraa, joita voidaan käyttää kasvuston tarkkailussa.

Taulukko 1. Kolme erilaista kameraa ja niiden ominaisuudet. Muokattu lähteistä MicaSense (2015), Mapir (2020) ja Senop (2020).

Kameran ominaisuus	Survey3W RGB	Micasense Rededge 3	Senop HSC-2
Kameran tyyppi	RGB-kamera	Multispektrikamera	Hyperspektrikamera
Resoluutio (Pikseliä)	4000x3000	1280x960	1024x1024
Alueiden määrä	3	5	1-1000
Paino (g)	50	150	990
Koko (mm)	59x41,5x36	121x66x46	199x131x97

Multispektrikamerat pystyvät mittaamaan säteilyä rajatulta aallonpituusalueelta kuten esimerkiksi punaisen värin aallonpituusalueelta. Näiden kameroiden ottamien kuvien avulla voidaan mitata, kuinka paljon kuvattava kohde heijastaa tietyn aallonpituusalueen säteilyä (Jensen ym. 2013). MicaSensen (2015) multispektrikameroihin on liitetty sensori, joka mittaa auringosta tulevan säteilyn intensiteettiä. Tämän jälkeen kameran sensori mittaa kasvustosta heijastuneen säteilyn intensiteetin tutkittavilta alueilta. Näiden edellä mainittujen mittaustietojen perusteella voidaan laskea kasvuston heijastusprosentteja, joista edelleen saadaan laskettua erilaisia kasvien terveyttä kuvaavia kasvillisuusindeksejä (Näsi ym. 2018, Maimaitijiang ym. 2020).

Multispektrikameroiden ominaisuudet voivat vaihdella paljon eri valmistajien ja mallien välillä (Taulukko 1). Rakenteeltaan ne voivat koostua useammasta kameralinssistä tai yksittäisestä linssistä. Kamera, jolla on useampi linssi ottaa jokaisen linssin kautta yhden kuvan, joka muodostuu tietyn alueen säteilystä. Alueen pituus, jolta kamera rekisteröi säteilyä vaihtelee kameroiden välillä (Jhan ym. 2017).

2.4 Kasvillisuusindeksit

Kasvillisuusindeksejä käytetään vähentämään ulkoisten tekijöiden aiheuttamaa häiriötä ja arvioimaan kasvuston ominaisuuksia (Kaufman ja Tanre 1992, Huete

ym. 1994, Fitzgeralda ym. 2010). Kasvillisuusindeksejä on monta erilaista (Bannari ym. 1995). Niiden avulla voidaan kuvata kasvuston eri ominaisuuksia, kuten typpipitoisuutta tai biomassan määrää (Fitzgeralda ym. 2010, Näsi ym. 2018, Viljanen ym. 2018). Myös kasvuston laatua, kuten lehtivihreäpitoisuutta, voidaan arvioida eri indeksien avulla (Rouse 1974, Wu ym. 2008). Kasvuston heijastusarvojen vaihtuessa muuttuvat myös niistä lasketut indeksit (Fitzgeralda ym. 2010, Bannari ym. 1995).

Hyödyllisten kuvien saaminen kasvustosta voi olla hankalaa, sillä rikkakasvit, varjot ja maaperä aiheuttavat kuviin häiriötä (Weidonga ym. 2001, Microimages 2012). Ilmakehän hiukkaset aiheuttavat myös häiriötä kasvustosta mitattuihin heijastusarvoihin (Guo ym. 2019). Ilmakehä vaikuttaa enemmän satelliittien ottamiin kuviin kuin dronella otettuihin kuviin (Guo ym. 2019). Näitä eri tekijöiden aiheuttamia häiriöitä voidaan pyrkiä pienentämään kokeellisten testien perusteella muodostettujen laskukaavojen avulla (Huete ym. 1994). Yhtälöön voidaan lisätä erilaisia kertoimia pienentämään esimerkiksi paljaan maan aiheuttamaa häiriötä kasvuston heijastusarvoihin. Kertoimet on määritetty kokeellisten mittauksien avulla ja ovat usein paikkakohtaisia (Huete ym. 1994).

Paljon käytetty kasvillisuusindeksi on NDVI (Normalized Difference Vegetation Index). Se kuvastaa vihreän kasvillisuuden määrää kuvatulla alueella (Rouse 1974). NDVI indeksin kaavan aallonpituusalueet vastaavat NIR eli lähi-infrapun ja punaisen (RED) värin aallonpituusaluetta. NIR säteilyn aallonpituus on 790 nm alueella ja punaisen värin aallonpituusalue on 670 nm alueella (Fitzgeralda ym. 2010). Kaavaan 1 sijoitetaan RED ja NIR kohdalle kyseisten aallonpituusalueiden heijastusarvot, jotka on mitattu multispektrikameralla. NDVI lasketaan kaavan 1 mukaan ja se voi saada arvoja väliltä -1 ja +1. Kasvuston NDVI arvo liikkuu 0,5 ja 0,8 välillä, kun taas paljaan maan arvo vaihtelee -0,1 ja 0,2 välillä (Carlson ja Ripley 1997).

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (1)$$

Toinen NDVI:n kaltainen kasvillisuusindeksi on NDRE eli Normalized Difference Red Edge (Kaava 2). NDRE kaavassa käytetään NIR ja red edge säteilyä, jossa 720 nm aallonpituus vastaa red edge aluetta ja 790 nm lähi-infrapun aluetta (Gitelson ja Merzylak 1994).

$$NDRE = \frac{NIR - \text{Red Edge}}{NIR + \text{Red Edge}} \quad (2)$$

SARVI (Soil Adjusted and Atmospherically Resistant Vegetation Index) on kasvillisuusindeksi, joka ottaa huomioon ympäristön aiheuttamia häiriöitä (Kaava 3). Kuvattaessa kasvustoa SARVI ottaa huomioon laskentakaaviossa maaperän ja ilmakehässä olevien pienhiukkasten aiheuttaman häiriön (Kaufman ja Tanre 1992, Huete ym. 1994). SARVI indeksi vähentää ilmassa olevien hiukkasten aiheuttamaa häiriötä vertaamalla sinisen ja punaisen värin heijastusprosenttien eroja (Kaufman ja Tanre 1992, Huete ym. 1994).

$$SARVI = \frac{NIR - (RED - \gamma(BLUE - RED))}{NIR + (RED - \gamma(BLUE - RED)) + L} \quad (3)$$

,jossa

L ja γ ovat empiirisiä kertoimia. L kerroin vähentää maan aiheuttamaa häiriötä ja γ kerroin ilmakehän aiheuttamaa häiriötä (Kaufman ja Tanre 1992, Huete ym. 1994).

Erilaisia kasvillisuusindeksejä on jo paljon ja uusia indeksejä kehitetään eri tutkimuksia varten (Taulukko 2) (Bannari ym. 1995, Bendig ym. 2015). Eri kasvillisuusindeksejä voidaan yhdistellä, jolloin voidaan luoda tarkempia malleja kasvuston ominaisuuksien arvioimiseen, kuten biomassan arvioimiseen (Bendig ym. 2015). Esimerkiksi multilineaarisessa regressiossa ja neuroverkoissa voidaan hyödyntää useampaa kasvillisuusindeksiä mallien luomiseen (Näsi ym. 2018, Maimaitijiang ym. 2020).

Taulukko 2. Erilaisia kasvillisuusindeksejä ja niiden laskukaavat. SARVI ja SAVI indeksien L muuttuja on kerroin.

Indeksi	Nimi	Kaava	Lähde
ExG	Excess Green Index	$2 * \text{Green} - \text{Red} - \text{Blue}$	Woebbecke ym. 1995
GNDVI	Green Normalized Difference Vegetation Index	$\frac{\text{NIR} - \text{Green}}{\text{NIR} + \text{Green}}$	Gitelson ja Merzylak 1996
GRVI	Green Red Vegetation Index	$\frac{\text{Green} - \text{Red}}{\text{Green} + \text{Red}}$	Tucker 1979
MSAVI	Modified Soil Adjusted Vegetation Index	$\frac{2 * \text{NIR} + 1 - \sqrt{(2 * \text{NIR} + 1)^2 - 8(\text{NIR} - \text{Red})}}{2}$	Qi ym. 1994
MTCI	MERIS Terrestrial Chlorophyll Index	$\frac{\text{NIR} - \text{Rededge}}{\text{Rededge} + \text{Red}}$	Dash ja Curran 2004
NDVI	Normalized Difference Vegetation Index	$\frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red}}$	Rouse ym. 1974
NDRE	Normalized Difference Red edge Index	$\frac{\text{NIR} - \text{Rededge}}{\text{NIR} + \text{Rededge}}$	Fitzgerald ym. 2010
OSAVI	Optimized Soil-Adjusted Vegetation Index	$1,16 * \frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red} + 0,16}$	Rondeaux ym. 1996
SARVI	Soil Adjusted and Atmospherically Resistant Vegetation Index	$\frac{\text{NIR} - (\text{Red} - \gamma(\text{Blue} - \text{Red}))}{\text{NIR} + (\text{Red} - \gamma(\text{Blue} - \text{Red})) + L}$	Huete ym. 1994
SAVI	Soil Adjusted Vegetation Index	$\frac{\text{NIR} - \text{Red}}{\text{NIR} + \text{Red} + L} * (1 + L)$	Huete 1988

2.5 Kasvuston 3D-mallinnus

3D-mallien luomiseen voidaan käyttää pistepilviä, joita voidaan tuottaa käyttäen laserskanneria ilmakuvauksissa. Skanneri pystyy laskemaan kuvattavan kohteen pisteiden sijainnit ja antamaan niille koordinaatit (Rusu ym. 2008). Tiheä pistepilvi mahdollistaa tarkan 3D-mallin tekemisen, mutta sen luominen vie tietokoneelta paljon aikaa (Pix4D 2017).

Dronen ottamien RGB-valokuvien pohjalta voidaan myös luoda 3D-malleja (Pix4D 2017). Näiden 3D-mallien luomiseen käytetään erilaisia algoritmeja, joiden avulla voidaan yhdistää pisteitä kaksiulotteisten kuvien välillä ja luoda 3D-malli kuvatusta alueesta (Aasen ym. 2015). 3D-mallien luomiseen dronen ottamien kuvien pohjalta löytyy erilaisia kaupallisia sovelluksia. Esimerkiksi Pix4D-ohjelma käyttää pistepilven luomiseen dronen ottamia kaksiulotteisia kuvia. Kuvien metadataan on tallennettuna koordinaatit ja korkeus, jossa kuvat on otettu

(Kuva 4). Näitä tietoja pystytään hyödyntämään pistepilveä luotaessa (Pix4D 2017).



Kuva 4. Multispektrikameran ottamiin kuviin tallentuu kuvien ottohetkellä kuvan koordinaatit sekä korkeus. Ne saadaan kuvien metadatasta (valkoinen laatikko kuvassa oikealla). RGB-kameran ottamiin kuviin tallentuu myös kuvaushetkellä koordinaatti ja korkeustiedot. Kuva Mikael Änäkkälä 2018.

3D-mallien luomiseen tarvitaan eri suunnista riittävä määrä kuvia kuvattavasta kohteesta. Tällöin saadaan luotua tarkempi 3D-malli (Pix4D 2017). Walterin ym. (2018) tekemässä tutkimuksessa 3D-mallinnettiin vehnäkasvustoa, joiden koeruudut olivat kooltaan 1,5 metriä pitkät ja 0,68 metriä leveät. Tuloksista todettiin, että kuvattavasta vehnäkoeruudusta saatiin tarkka 3D-malli 48 kuvalla. Tätä suurempi määrä kuvia ei parantanut 3D-mallien tarkkuutta merkittävästi.

3D-malleja voidaan käyttää kasvuston maanpäällisen biomassan sekä kasvuston korkeuden arvioimiseen (Walter ym. 2018). Kaupallisista sovelluksista löytyy erilaisia työkaluja, joilla voidaan tehdä laskutoimenpiteitä 3D-mallista. Esimerkiksi Pix4D (2017) sovelluksella voidaan laskea tilavuuksia halutusta kohteesta. Laskenta perustuu siihen, että ohjelma tunnistaa pistepilvestä yhden pisteen ja sen

muodostaman kaksiulotteisen pinta-alan. Tämän jälkeen lasketaan pisteen korkeus valittuun nollapisteeseen verrattuna. Kertomalla pisteen muodostama pinta-ala sen korkeudella saadaan laskettua tilavuus. Täten laskemalla pistepilvestä kasvuston kaikki pisteet saadaan laskettua koko kasvuston muodostama tilavuus (Pix4D 2017).

2.6 Dronekuvausten soveltaminen maataloudessa

Droneja voidaan käyttää moneen tarkoitukseen maataloudessa (Taulukko 3). Dronejen avulla voidaan etsiä rikkakasveja ja arvioida niiden levinneisyyttä pellolla (Peña ym. 2013). Sen lisäksi dronen ottamilla kuvilla voidaan arvioida kasvien korkeutta ja maanpäällistä biomassaa (Viljanen ym. 2018, Walter ym. 2018). Droneissa on enimmäkseen käytetty hyperspektri- tai RGB-kameroita. Hyperspektrillä on arvioitu kasvuston biomassoja, kun taas RGB-kameroita on käytetty enemmän kasvuston korkeuden arvioimiseen (Näsi ym. 2018, Walter ym. 2018).

Taulukko 3. Tutkimuksissa on hyödynnetty erilaisia kameroita kasvuston eri ominaisuuksien arvioimisessa. Kasvuston heijastusarvojen mittaamisessa on käytetty dronejen ja satelliittien kuvia tai käsin käytettäviä mittalaitteita.

Mitä tutkittu	Tutkittava kasvi	Kamera/valo	Viite
Biomassa	Nurmi	Hyperspektri ja RGB	Viljanen ym.2018
Biomassa	Ohra	Hyperspektri ja RGB	Bendig ym. 2015
Biomassa	Vehnä	RGB	Walter ym. 2018
Biomassa ja typpipitoisuus	Nurmi ja ohra	Hyperspektri ja RGB	Näsi ym. 2018
Rikkakasvien kartoittaminen	Maissi	Multispektri	Peña ym. 2013
Lehtivihreäpitoisuus	Vehnä	Hyperspektri	Wu ym. 2008

Rikkakasvien tunnistamisessa pellolla on käytetty apuna dronella otettuja kuvia. Peñan ym. (2013) tutkimuksessa rikkakasveista tehtiin kartta, josta voitiin määrittää, kuinka laajalle alueelle rikkakasvit olivat levittäytyneet. Tämä rikkakasvien tunnistamisjärjestelmä koostui kolmesta osasta. Aluksi järjestelmä tunnistaa viljeltävän kasvin muodostamat viljelyrivit pellolla. Tämän jälkeen järjestelmä tunnistaa rikkakasvin viljelyrivien ulkopuolelta. Lopuksi systeemi luo pellosta kartan, joka koostui ruudukoista, jotka ovat väritetty rikkakasvien esiintymisen perusteella. Tutkimuksessa käytettiin Tetracam mini-MCA-6 multispektrikameraa, joka otti kuvia kuudelta eri aallonpituusalueelta (Peña ym. 2013).

Dronejen ottamien kuvien ja kasvin korkeustietojen perusteella on arvioitu kasvien biomassan määrää pellolla. Myös tavallisella RGB-kameralla otetuista kuvista voidaan laskea erilaisia kasvillisuusindeksejä, mutta ne sopivat parhaiten käytettäväksi kasvin alku kasvuvaiheessa (Bendig ym. 2015). Kasvuston biomassojen arvioiminen perustuu dronekuvista laskettuihin kasvillisuusindekseihin. Peltojen biomassojen muuttuessa, muuttuvat myös kasvillisuusindeksien arvot. Näiden indeksien ja biomassojen välistä riippuvuutta voidaan laskea erilaisilla regressioanalyysillä, kuten lineaarisella tai multilineaarisella regressiolla (Bendig ym. 2015).

Useissa tutkimuksissa on laskettu pelloilla kasvavien kasvien biomassaa ja muita ominaisuuksia käyttäen erilaisia kameroita dronessa. Näsin ym. (2018) tutkimuksessa hyödynnettiin droneen asennettua hyperspektrikameraa ja tavallista RGB-kameraa. Hyperspektrikameralla kerättiin heijastusarvoja eri aallonpituusalueelta, joista laskettiin erilaisia kasvillisuusindeksejä kuten NDVI. RGB-kameran kuvista voidaan laskea erilaisia kasvillisuusindeksejä kuten ExG (Excess green index) sekä luoda 3D-malleja. 3D-malleista saadaan laskettua kasvuston korkeusarvoja. Tutkimuksen tulokset osoittivat, että yhdistämällä hyperspektrikameran tuloksia 3D-mallilla määritettyihin korkeustietoihin saatiin parhaimpia ennusteita kasvuston biomassoista. Myös tavallisen RGB-kameran kuvien yhdistäminen korkeustietoihin tuotti hyviä tuloksia. Hyperspektrikamerasta ja RGB-kamerasta saadut mittaukset käsiteltiin Random forest koneoppimisen kautta, jonka avulla laskettiin arvioita kasvuston biomassoille. Arvioitujen biomassojen ja kentältä mitattujen biomassojen väliltä laskettiin Pearsonin korrelaatio. Hyperspektrikameran heijastusarvojen ja ohran kuiva-aineen biomassojen välinen Pearsonin korrelaatio oli 0,89–0,94 ja RGB-kameran ja kuiva-ainemassojen välinen korrelaatio oli 0,85–0,94 lennettäessä 140 metrissä (Näsi ym. 2018). Nurmella vastaavat arvot olivat hyperspektrillä 0,72 ja RGB-kameralla 0,10–0,71 50 metrissä lennettäessä. Yhdistämällä 3D mallista saadut tiedot hyperspektri- ja RGB-kameran kuviin oli korrelaation arvo 0,92–0,95 ohralla ja nurmella 0,64–0,67 (Näsi ym. 2018).

3. Tutkimuksen tavoitteet

Tutkimuksen tavoitteena oli selvittää, kuinka droneja voitaisiin käyttää eri kasvien kasvuston tarkkailussa. Monissa aiemmissa tutkimuksissa niitä on hyödynnetty korkeintaan muutaman kasvin osalta samassa hankkeessa. Tässä tutkimuksessa kuvauskohteena oli alkuperäisen suunnitelman mukaan kuusi erilaista kasvia samassa kokeessa. Ensisijaisena tavoitteena oli selvittää, millä tarkkuudella voidaan multispektrikameran viidellä alueella ja niistä laskettavalla kasvillisuusindeksillä arvioida kasvuston kuiva-ainemassaa, lehtivihreäpitoisuutta ja lehtialaa. Toisena tavoitteena oli selvittää, miten tavallinen RGB-kameran käyttö dronekuvauksissa soveltuu kasvuston biomassan ja lehtialan arviointiin. Sen lisäksi tutkimuksessa pyritään vertaamaan sitä, kumpi edellä mainituista menetelmistä soveltuu paremmin kasvuston biomassan ja lehtialan arvioimiseen.

4. Aineisto ja menetelmät

Tutkimuksen aineisto kerätiin kasvukaudella 2018 tehdystä NiCrop –hankkeen (Kohti typpiomavaraista kasvinvuorotusta – muuttuvatko kaasumaiset typpipäästöt) kenttäkokeesta. Tässä luvussa käydään läpi, minkälaisia mittauksia tutkimuskesän aikana tehtiin kasvustosta ja koealueelta. Sen lisäksi esitellään koekentällä käytettyjä mittausvälineitä ja niiden toimintaperiaatteita. Droneen asennettujen kameroiden ottamien kuvien jälkikäsitteily ja niiden lukemiseen tehty Matlab-ohjelman koodi on erittäin tärkeä osa tutkimusta ja tätä työtä.

4.1 Tutkimusalueen esittely

Kenttäkoe sijaitsi Helsingissä, Haltialassa Laamannintiellä (60°15'55.7"N ja 24°57'27.7"E). Peltolohko saatiin käyttöön Haltialan kotieläintilalta kolmen vuoden kokeita varten. Kenttäkoe aloitettiin keväällä 2017, jolloin muille kuin avokesanto- ja kauran monokulttuurikoeruuduille kylvettiin härkäpapua (*Vicia faba*). Tutkimusvuonna kylvöalusta muokattiin sängellä olleeseen maahan tasojyrsimellä ja koeruudut kylvettiin 16.5.2018 ja tämän kasvukauden aikana otettiin kuvia dronella tutkimusta varten (Kuva 5). Kylvörivien väli oli 12,5 cm ja tavoiteltu kylvötiheys (itävää siementä/m²): härkäpapu (*Vicia faba*) 70, rapsi (*Brassica napus subsp. oleifera*) 150, hamppu (*Cannabis sativa*) 200, kaura (*Avena sativa*) 500, kevätvehnä (*Triticum aestivum*) 700 ja pellava (*Linum usitatissimum*) 800. Kerranteita oli neljä ja jokaisessa kerranteessa oli kymmenen koeruutua (Kuvat 6 ja 7). Koeruutujen koko oli 1,5 x 15 m. Vuonna 2018 kentällä viljellyt kasvit ja niiden typpilannoitus esitetään kuvassa 6. Kasvinsuojelu tehtiin tarpeen mukaan. Koeruudut sijaitsivat alle viiden kilometrin säteellä Helsinki-Vantaan lentokentästä, joten dronen lennättämiseen piti kysyä lupaa lentokentältä. Kyseiselle alueelle saatiin lentolupa koko kasvukauden ajaksi.



Kuva 5. Ilmakuva koekentältä. Siinä näkyy ruudut kylvöpäivänä 16.5.2018. Kuvan oikeassa reunassa on ensimmäinen kerranne ja vasemmassa reunassa neljäs kerranne. Kuva otettiin RGB-kameralla DJI Phantom 4 Advance merkkisellä dronella, jota käytettiin myös kasvuston kuvauksissa. Kuva Mikael Änäkkälä 2018.

Kerranne	Kerranne	Kerranne	Kerranne
1	2	3	4
sr	sr	sr	sr
1	2	10	5
3	7	8	7
5	10	6	9
8	5	4	10
4	3	2	6
7	8	9	1
9	6	3	4
6	4	1	3
2	1	7	2
10	9	5	8
sr	sr	sr	sr

Kuva 6. Kenttäkoekartta ja koetekijöiden 1–10 kasvit vuonna 2018. Sulkujen sisällä on merkattu typpilannoitteen määrä. 1 avokesanto, 2 härkäpapu (20 kg N), 3 kaura (90 kg

N), 4 kevätvehnä (90 kg N), 5 rapsi (90 kg N), 6 hamppu (50 kg N), 7 rapsi (Ei N), 8 kaura (50 kg N), 9 kaura (Ei N), 10 pellava (50 kg N) ja sr on suojaruutu. Koetekijöitä 1 ja 3 lukuun ottamatta esikasvi oli härkäpapu. Kuva Mikael Änäkkälä 2018.



Kuva 7. Koeruuduista luotu ortomosaiikkikuva. Vasemmassa yläreunassa on ensimmäinen kerranne ja oikeassa alanurkassa neljäs kerranne. Kuva on otettu 30.7.2018. Kuva Mikael Änäkkälä 2018.

4.2 Koevuonna kenttäkokeesta tehdyt mittaukset

Tavoitteena oli ottaa jokaiselta koeruudulta kesän aikana viidestä eri kasvuvaiheesta (kasvullisesta vaiheesta, kukkien muodostumisvaiheesta, kukinnasta, jyväntäyttymisvaiheesta ja keltatuleentumisvaiheesta, Haarala (2020)) biomassanäytteet, jolloin pystyttiin arvioimaan kasvuston kehitystä ja biomassan kertymistä. Biomassoja kerätessä jokaisesta koeruudusta otettiin kolme osanäytettä. Tällöin jokaisesta koeruudusta tuli kolme biomassanäytettä. Yksittäinen biomassanäyte kerättiin 0,5 m matkalta kylvörivistä. Jokainen biomassanäyte käsiteltiin erikseen, jotta dronekuvauksille saataisiin mahdollisimman paljon verrannedatua. Biomassanäytteet käsiteltiin myöhemmin laboratoriossa, jossa jokaisesta kasvista eroteltiin varret, lehdet ja tähkät/röyhyt/idut erilleen toisistaan. Tämän jälkeen eritellyt kasvin osat punnittiin tuorepainon määrittämiseksi. Tämän

jälkeen kasvin osat kuivattiin uunissa 80 asteessa vähintään 2 päivän ajan. Kuivauksen jälkeen kyseiset näytteet punnittiin uudelleen, jolloin saatiin niiden kuivapaino (menetelmät kuvattu Haaran (2020) julkaisussa). Kasvukauden aikana kasvustosta mitattiin näytteenottoaikana myös lehtivihreä jokaisesta biomassanäytteestä Apogee MC-100 (Apogee Instruments 2019c) lehtivihreämittarilla ja lehtialaindeksi koko koeruudusta kolmesta mittauspisteestä AccuPAR LP-80 (Apogee Instruments 2006) laitteella.

4.2.1 Lehtivihreän mittaaminen

Lehtivihreän mittaamiseen käytettiin Apogee MC-100 merkkistä lehtivihreämittaria. Jokaisesta biomassanäytteestä mitattiin 10 lehtivihreämittausta. Mittauksen yksikkö oli $\mu\text{mol}/\text{m}^2$. Laitteen toiminta perustuu kahteen diodiin, jotka lähettävät punaista ja lähi-infrapuna säteilyä (Apogee Instruments. 2019c). Laite mittaa sen, kuinka suuri osa edellä mainituista säteilystä pääsee näytteen läpi. Käyttämällä kasvikohtaisia valmistajan ilmoittamia kertoimia voidaan laskea kasvien lehtivihreäpitoisuus (Apogee Instruments. 2019c). Lehtivihreän mittauksia on tarkoituksena verrata multispektrikameran heijastusarvoihin.

4.2.2 Lehtialaindeksin mittaaminen

Lehtialaindeksin (LAI) mittaamiseen käytettiin AccuPAR LP-80 –laitetta ja sen yksikkö on m^2/m^2 . Apogee Instruments (2006) mittalaitteen toiminta perustuu kahteen säteilyä mittaavaan anturiin. Ensimmäinen anturi tulee asettaa kasvuston yläpuolelle, joka mittaa auringosta tulevaa säteilyä. Toinen antureista tulee sijoittaa maan tasalle, jossa se mittaa maahan tulevan säteilyn määrää. Mittaamalla nämä kaksi säteilyarvoa ja käyttämällä valmistajan ilmoittamia kasvikohtaisia kertoimia, voidaan laskea kasvuston lehtialaindeksi. Lehtialaindeksi kuvastaa kuinka paljon tietyllä maa-alalla on kasvien lehtien muodostamaa pinta-alaa. Mitä suurempi LAI arvo on, sitä enemmän kasvulla on yhteyttävää pinta-alaa. Lehtialaindeksi mitattiin jokaisesta koeruudusta kesän aikana viitenä eri ajankohtana, biomassojen keräyksien yhteydessä. Jokaisesta koeruudusta mitattiin kolmesta eri kohdasta LAI ja niiden keskiarvo edusti yksittäisen koeruudun LAI arvoa. LAI:n arvoja verrataan multispektrikameran heijastusarvoihin ja 3D-mallien tilavuuksiin.

4.2.3 Lämpötilan, sademäärän ja säteilyn mittaaminen

Koelohkolle oli asennettu kaksi kappaletta Hobo Pendant Event dataloggeria (Onset Computer Corporation 2020), joista ensimmäinen asennettiin 1. ja 2. kerranteen väliin ja toinen asennettiin 3. ja 4. kerranteen välille. Hobowaret mittasivat kesän aikana ilman lämpötilaa ja sademäärää. Dataloggerin päällä oli kartio, joka keräsi tietylle pinta-alalle sataneen sademäärän ja keräsi vedet pieneen mittastiaan. Mittastiaan täyttyessä se kaatui ja tyhjeni. Kaatuessaan dataloggeri rekisteröi yhden mittauksen sekä päivämäärän ja kellonajan. Mittaamalla astian tilavuus ja laskemalla kaatumisten määrän, voitiin laskea vuorokauden sadessumma. Lohkolle asennettiin myös kaksi erillistä anturia, jotka mittasivat tulevan auringonsäteilyn määrää. Kyseiset anturit olivat Decagonin valmistamat PYR (Pyranometer) ja PAR (Photosynthetically Active Radiation) -anturit. Anturit olivat liitetty Decagon Em50 dataloggeriin, jonne antureiden mittaustiedot tallentuivat. Anturit mittasivat auringon säteilyn voimakkuutta 30 minuutin välein. PAR sensorin mittausalue oli 0–5000 $\mu\text{mol}/(\text{m}^2\text{s})$ (Decagon devices 2014). PYR sensorin mittausalue on 0–1750 W/m^2 (Apogee instruments 2020).

4.3 Ilmakuvaukset

Ilmakuvaukset suoritettiin kahdella dronella 50 ja 20 metrin korkeudessa. Koeruudut kuvattiin 3–4 kertaa 50 metristä multispektrikameralla varustetulla dronella. 20 metrin korkeudelta suoritettiin yksi lento DJI Phantom 4 Advance dronella 3D-malleja varten. Kuvattavien koeruutujen reunoille sijoitettiin muovinpalasia, joiden avulla pystyttiin tunnistamaan biomassojen näytteidenottopaikat. Sen lisäksi koeruuduille sijoitettiin viisi kiinteää pylvästä kiintopisteiksi kerranteiden väliin, joiden avulla voitiin erottaa kerranteet toisistaan.

4.3.1 Dronet ja kamerat

Koealueella lennettiin kahdella eri dronella. Ensimmäinen drone oli DJI:n valmistama Phantom 4 Advance. Tässä dronessa oli RGB-kamera, jolla kuvattiin koeruudut ja joista luotiin 3D-malli (Kuva 1) (DJI 2020). Toinen drone oli 3DR Solo, johon oli jälkiasennettu MicaSense RedEdge 3 multispektrikamera (Kuvat 3 ja 8) (MicaSense 2015, 3DR 2020). Kamera otti kuvia viideltä eri aallonpituusalueelta, jotka olivat sininen, vihreä, punainen, lähi-infrapuna ja red edge (MicaSense

2015). Näiden aallonpituusalueiden keskikohta on edellä mainitun alueiden järjestyksen mukaisesti 475, 560, 668, 840 ja 717 nm ja kyseisten alueiden leveys on 20, 20, 10, 40 ja 10 nm (MicaSense 2015). Taulukossa 4 esitetään tarkempia tietoja droneista.



Kuva 8. Tutkimuksessa käytetty Micasense Rededge 3 multispektrikamera, jolle rakennettiin oma vakain. Tällöin kameralla otetut kuvat olivat aina vaakatasossa. Kamera ja sen vakain (kiinni dronen alla) asennettuna 3DR Solo droneen. Kuva Mikael Änäckälä 2018.

Taulukko 4. 3DR Solon lentoaika määritettiin omien kokemusten perusteella. Vakaimen ja multispektrikameran asentaminen droneeseen lisäsi sen painoa ja lyhensi sen lentoaikaa. 3DR Solon kameran resoluutio on multispektrikameran resoluutio. Muokattu lähteistä (Mydronelab 2016, DJI 2020).

	DJI Phantom 4 Advance	3DR Solo
Akun koko (mAh)	5870	5200
Lentoaika (min)	30	7
Kamera (Mpx)	20	1,2
Vakain	On	Itsetehty
Paino (g)	1368	2100

Sekä multispektrikameran että RGB-kameran ottamat kuvat käsiteltiin Pix4D ohjelmalla (Pix4D 2017). Multispektrikameralla otetut kuvat yhdistettiin ortomosaiikkikuviksi ja jokaisesta aallonpituusalueesta saatiin luotua omat heijastuskartat. Näistä heijastuskartoista voitiin mitata, kuinka paljon kasvusto heijasti auringosta tulevaa säteilyä. Kameran kuvat kalibroitiin jokaiselle kuvauskerralle MicaSensen

oman heijastuspaneelin avulla, jolle oli annettu tarkat heijastusarvot (Pix4D 2019b). DJI 4 Phantom:illa otetut kuvat käsiteltiin myös Pix4D sovelluksella, mutta niitä ei tarvinnut kalibroida erikseen 3D-mallin luomista varten. 3D-mallista aiotaan mitata tilavuuksia ja verrata niitä kasvuston biomassoihin (Pix4D 2017).

4.3.2 Automaattiset lentotehtävät ja kuvausajat

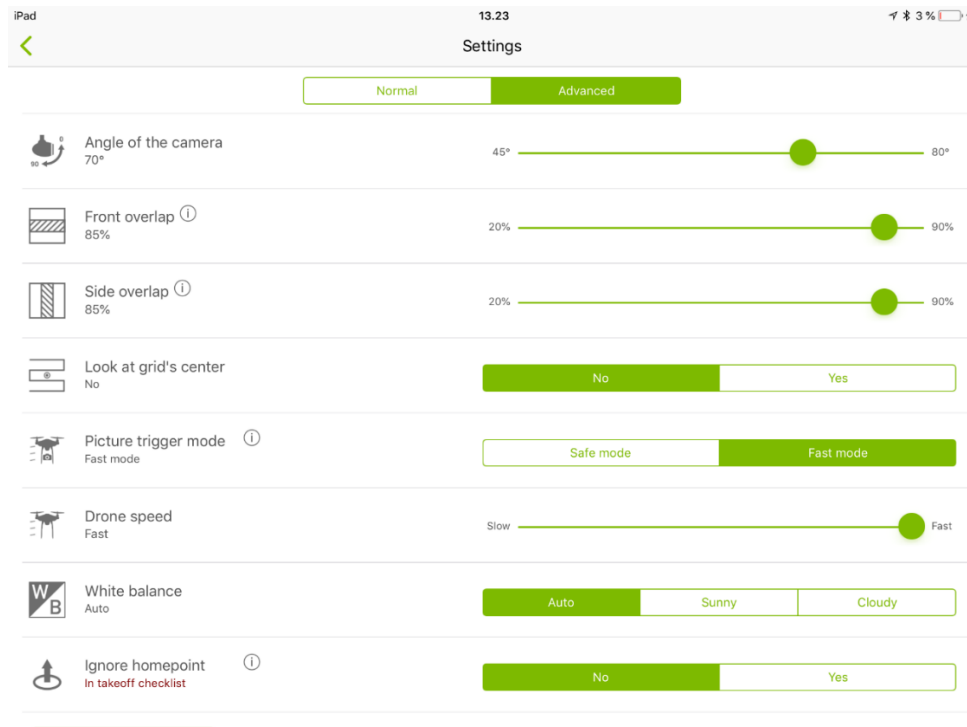
Molempien dronejen lennätyksessä käytettiin Pix4Dcapture sovellusta, jolla pysyy suorittamaan automaattisia lentotehtäviä (Pix4D 2020). 3DR Solo:n lennätyksessä käytettiin Pix4Dcapture 3.0, joka on vanhempi versio kyseisestä sovelluksesta. Ainoastaan vanhempi versio Pix4Dcapturesta oli yhteensopiva 3DR Solon kanssa. Multispektrikuvauksissa lentokorkeus oli 50 metriä (Kuva 9). Sovellukseen oli asetettu *overlap* arvoksi 90 % (Kuva 9). Overlap kuvasti sitä, kuinka paljon dronen lentämä reitti oli päällekkäin kameran ottamien kuvien kanssa (Pix4D. 2019a). Mitä suurempi overlapin arvo on, sitä pidempi lentoreitti dronelle tulee. Multispektrikuvauksessa lentoaika oli 50 metrissä noin 7 min. Kyseisen dronen maksimilentoaika on hieman yli 7 minuuttia, koska multispektrikameran asennus toi lisää painoa droneen, mikä vuorostaan kuluttaa enemmän energiaa lentäessä. DJI Phantom 4 Advancella suoritettiin 3D lentoja 20 metrissä (Kuva 10 ja 11). Lentoajaksi tuli 20 metrissä noin 19 minuuttia.



Kuva 9. Multispektrikameralla käytetty lentosuunnitelma. Lennettäessä 50 metrissä, multispektrikameran kuvien pikselin koko on 3,26 cm/pikseli. Kuvassa on valkoinen viiva, jonka mukaan drone lensi tutkittavan alueen läpi yhden kerran. Kuva Mikael Änäkkälä 2018.



Kuva 10. 3D-mallinnuksessa käytetty lentosuunnitelma 20 metrin korkeudelta. 3D-mallia varten lennettiin kuvattava ala kaksi kertaa läpi eri suunnista, jotta saatiin luotua riittävän tarkka 3D-malli. Sen lisäksi kameran tuli olla pienessä kulmassa, jotta voitiin luoda tarkempi 3D-malli. Kuva Mikael Änäkkälä 2018.



Kuva 11. Kuvassa 10 esitetyn lentosuunnitelman tiedot. Overlap kuvastaa kuvien päällekkäisyyttä. Angle of the camera- kohdassa voidaan säätää kameran kulmaa vaakatasoon verrattuna. Otettaessa kuvia 3D-mallia varten tulee kameran olla pienessä kulmassa 45 ja 80 asteen väliltä. Kuva Mikael Änäkkälä 2018.

Alkuperäinen suunnitelma oli ottaa kuvia viidestä eri kasvuvaiheesta kesän aikana. Hampusta ja rapsista saatiin kesän aikana otettua neljästä eri kasvuvaiheesta kuvat. Ensimmäinen kuvauskerta (15.7.2018) jäi ottamatta, koska sään takia dronea ei pystynyt lennättämään. Härkäpavulla, kauralla ja vehnällä kuvia otettiin kolmesta eri kasvuvaiheesta. 1. ja 2. kasvuvaiheesta otettiin kuvat, mutta koska kasvit olivat niin pieniä, näytteiden paikkaa kuvista oli mahdoton määrittää.

Hampun ja rapsin kuvat otettiin 14.7., 30.7., 13.8. ja 27.8.2018 (Taulukko 5). Kauran, vehnän ja härkäpavun kuvat otettiin 9.7., 23.7. ja 7.8.2018 (Taulukko 5). Koska kuvausdataa kertyi paljon ja kuvien käsitteleminen vie paljon aikaa, tutkimuksessa käsitellään ainoastaan viimeisimmän kuvauspäivän datat. Tämä tarkoittaa sitä, että hampun ja rapsin kohdalla tarkasteltiin 27.8. dataa ja kauran, vehnän ja härkäpavun kohdalla 7.8. dataa. Kaikilla kasveilla tehtiin neljä kappaletta 50 metrin lentoja multispektrikameroilla, joiden tulokset esitellään tulevissa kappaleissa. Taulukossa 5 esitetään kasvien kuvauspäivät ja niiden kasvuvaiheet BBCH- tai Zadoks-asteikolla. RGB-kameralla otettiin kuvia yhden lennon verran 20 metristä 3D-mallia varten taulukossa 5 esitettyinä päivinä.

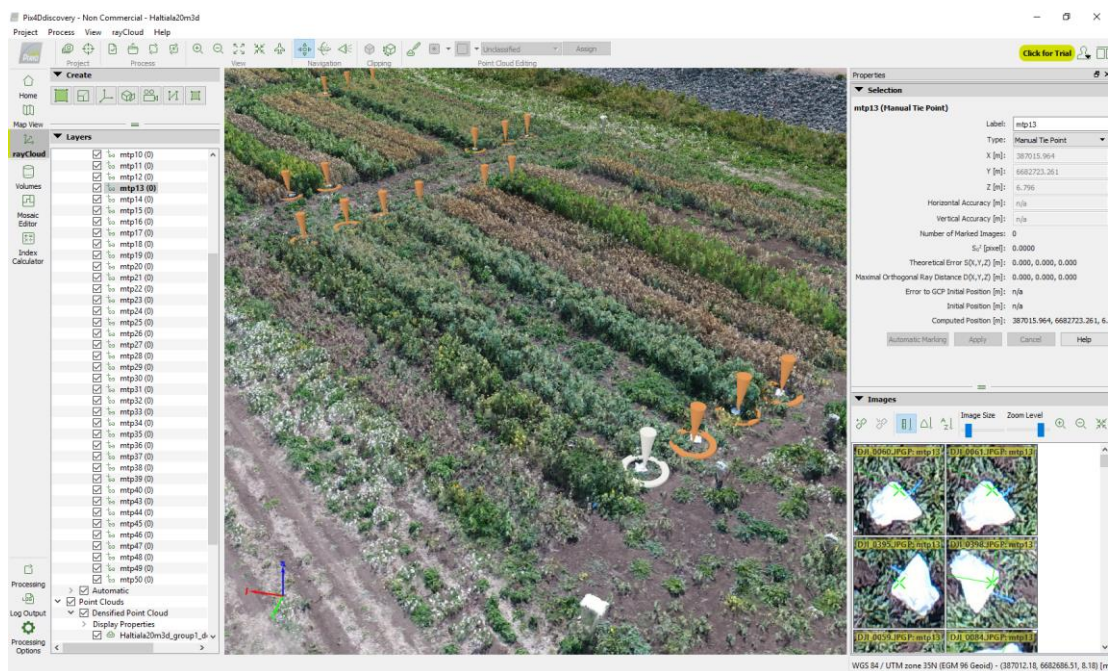
Taulukko 5. Eri kasvien kuvauspäivät ja niiden kehitysvaiheet (suluissa). 2 härkäpapu (20 kg N), 3 kaura (90 kg N), 4 kevätehnä (90 kg N), 5 rapsi (90 kg N), 7 rapsi (Ei N), 8 kaura (50 kg N), 9 kaura (Ei N). Kasvien kehitysvaiheet on ilmoitettu BBCH- (Hack ym. 1992) tai Zadoks-asteikon mukaan (Zadoks ym. 1974).

Kasvi (kasvuasteikko)	1 Kuvaus	2 Kuvaus	3 Kuvaus	4 Kuvaus	5 Kuvaus
2 (BBCH)	14.6. (13)	26.6. (32)	9.7. (60)	23.7. (67)	7.8. (79)
3 (Zadoks)	14.6. (21)	26.6. (47)	9.7. (56)	23.7. (68)	7.8. (85)
4 (Zadoks)	14.6. (21)	26.6. (40)	9.7. (52)	23.7. (64)	7.8. (75)
5 (BBCH)	Ei ole	14.7. (33)	30.7. (61)	13.8. (72)	27.8. (82)
7 (BBCH)	Ei ole	14.7. (33)	30.7. (61)	13.8. (72)	27.8. (82)
8 (Zadoks)	14.6. (21)	26.6. (45)	9.7. (56)	23.7. (68)	7.8. (77)
9 (Zadoks)	14.6. (21)	26.6. (45)	9.7. (56)	23.7. (68)	7.8. (75)

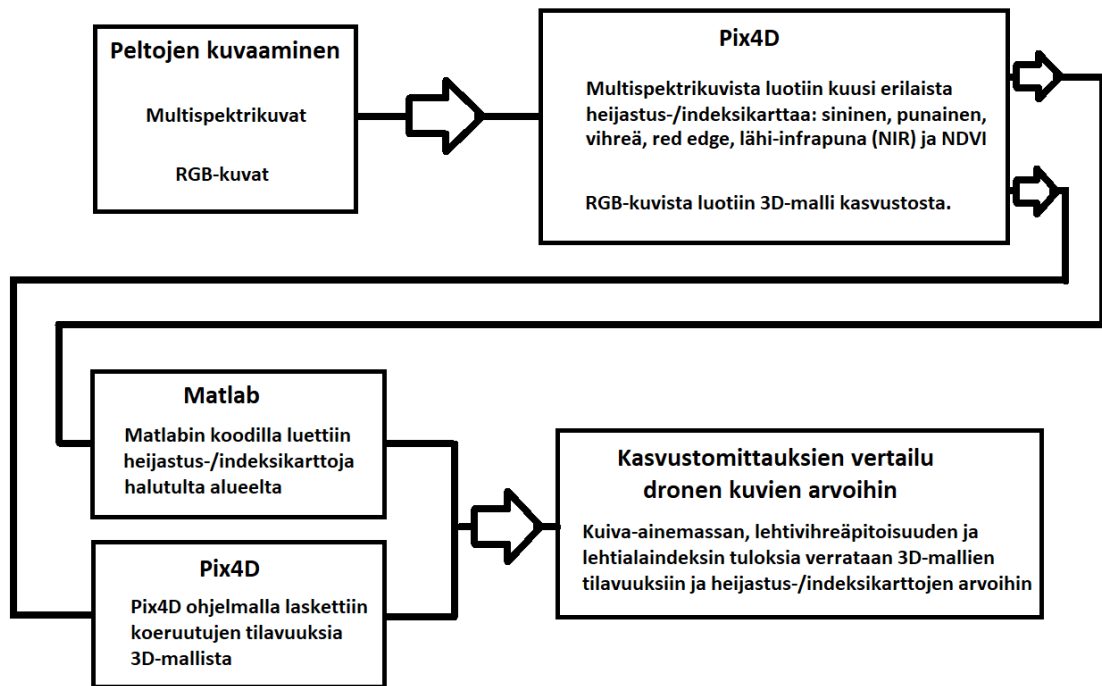
4.4 Multispektrikameran kuvien käsittely

Multispektrikameran kuvien pikseliarvojen lukemisessa käytettiin Matlab -ohjelmaa. Ohjelmaan kirjoitettiin koodi, johon voitiin syöttää näytteenottopaikkojen koordinaatit tai koeruudun koordinaatit. Tämän jälkeen ohjelma luki kuvien pikseliarvot halutulta alueelta. Yksittäisen pikselin arvo liikkui 0 ja 1 välillä ja kuvasti

kasvuston heijastusarvoa. Eli pikselin arvo 1 tarkoitti, että kasvusto heijasti 100 % auringosta tulevasta säteilystä. Pikselien sisältämiä heijastusarvoja verrattiin kasvuston biomassoihin, lehtivihreäpitoisuuteen ja lehtialaindeksiin. Luettaessa yksittäisten näytteiden pikseliarvoja pyrittiin lukemaan alue, jolta näyte oli otettu eli 50 cm x 12,5 cm alue. Luettaessa koko koeruudun pikseliarvot, asetettiin näyteruudun pituudeksi 14 metriä ja leveydeksi 7 x 12,5 cm. Tällä vältettiin se, ettei ohjelman koodi lukenut reunimmaisista kylvöriveistä, joista ei kerätty biomassanäytteitä. Näin voitiin myös rajata koeruutujen ulkoreunat pois lukuohjelmasta, jolloin välttyttiin siltä virheeltä, että koodi lukisi koeruutujen välissä ollutta paljasta maata. Paljaan maan heijastusarvo poikkeaa kasvuston heijastusarvosta (Microimages 2012). Koeruutujen reunoilla levitettiin muovinpalasia, mikä helpotti näytteenotto-paikkojen löytämistä (Kuva 12). Kuvassa 13 on esitettyä kuvien koko käsittely-prosessi.



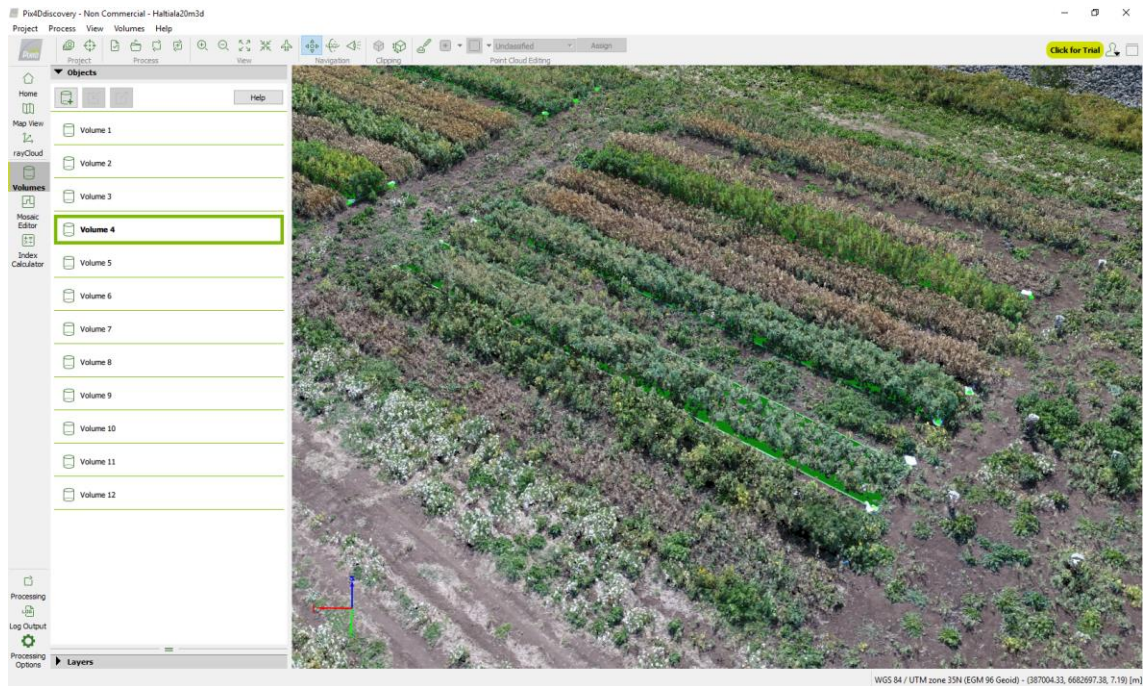
Kuva 12. Pix4D ohjelmalla luotu 3D-malli kasvustosta. Koeruutujen reunojen tunnistamiseen käytettiin muovin palasia, jotka näkyivät hyvin ilmasta otetuista kuvista. Kuva Mikael Änäckälä 2019.



Kuva 13. Dronekuvien käsittelyprosessi. Matlabilla tehty koodi mahdollisti yksittäisten näytteiden tarkemman lukemisen heijastus-/indeksikartoista. 3D-mallin tilavuuksia luettaessa, luettiin koko koeruutu. Multispektrikameran tuloksia laskettaessa luettiin koko koeruutu sekä yksittäisten biomassojen näytteidenottopaikat.

4.5 3D-mallien käsittely

Koeruuduista otettiin 20 metrin korkeudelta RGB-kuvia, joiden avulla luotiin 3D-malli Pix4D ohjelmalla. Pix4D sisältää työkalun, jolla voi laskea tilavuuksia 3D-mallista (Kuva 14). Tätä työkalua käytettiin lukemaan koeruutujen tilavuuksia. Koeruutujen jokaiselle reunalle asetettiin 3D-mallissa mittauspisteitä, jonka jälkeen ohjelma piirsi mittauspisteiden sisälle neliön. 3D-malli koostuu pisteistä, joilla jokaisella on oma tarkka kolmiulotteinen sijaintinsa. Tämän jälkeen ohjelma laski jokaisen pisteen korkeuden koordinaatit, jolloin saadaan pisteiden korkeusarvot. Laskemalla kaikkien neliön sisällä olevien pisteiden korkeustiedot ja kun jokaisen pisteen pinta-ala tiedetään, pystyy ohjelma laskemaan tutkittavan kohteen tilavuuden 3D-mallista (Pix4D 2017).



Kuva 14. 3D-malli koeruuduista, joka on luoto 20 metrin korkeudelta otettujen kuvien pohjalta. Ohjelmaan merkattiin koeruutujen reunat, jonka jälkeen ohjelma piirsi reunojen sisään alueen. Alueen sisältä ohjelma pystyi laskemaan kasvuston viemän tilavuuden. Kuva Mikael Änäckälä 2019.

3D-mallien tuloksia laskettaessa käytettiin useamman kuvauspäivän tuloksia kesän ajalta (Taulukko 5). Laskuissa käytettiin kasvien 5, 6 ja 7 kohdalla neljää kuvauspäivää (14.7., 30.7., 13.8. ja 27.8.) ja kasvien 2, 3, 4, 8 ja 9 kolmea kuvauspäivää (9.7., 23.7. ja 7.8.).

4.6 Dronekuvauksien tulosten vertailu kasvuston ominaisuuksiin

Tässä tutkimuksessa verrattiin kuinka eri aallonpituusalueen heijastusarvot ja niistä lasketut indeksit korreloivat kuvausten aikana määritettyjen lehtialaindeksin (LAI), lehtien lehtivihreäpitoisuuden ja kasvuston biomassojen kanssa. Multispektrikuvista laskettiin heijastusarvoja kahdella eri tarkkuudella. Osa heijastusarvojen ja muiden mittausten välisistä riippuvuuksista on laskettu jokaisen näytteen avulla eli $12,5 \times 50 \text{ cm}^2$ alueelta, joita oli kolme kappaletta jokaiselta koeruudulta. Toinen osa tuloksista on laskettu lukemalla koko koeruudun heijastusarvo eli $1,5 \times 15 \text{ m}^2$ alalta. Käsiteltäessä koko koeruudun mittausarvoja (kuiva-ainemassaa, lehtivihreäpitoisuutta ja LAI:ta) on laskuissa käytetty kolmen näytteen keskiarvoa. Yksittäisten näytteiden heijastusarvojen korrelaatio laskettiin kuiva-

ainemassojen ja lehtivihreäpitoisuuden välillä. Koko koeruudun heijastusarvojen korrelaatio laskettiin kuiva-ainemassojen, lehtivihreäpitoisuuden ja LAI välillä.

Jokaisesta koeruudusta otettiin kolme biomassanäytettä. 3D-mallien tuloksien laskuissa on käytetty kolmen biomassanäytteen keskiarvoa. 3D-mallin tilavuudet on laskettu koeruutu kohtaisesti eli 1,5*15 neliömetrin alalta.

Multispektrikameran ja 3D-mallien tuloksista laskettiin Pearsonin lineaarinen korrelaatio (Kaava 4), selitysaste (Kaava 5, jolla arvioitiin lineaarisen mallin kykyä kuvata riippuvuutta) ja RMSE (Root mean square error) (Kaava 6). Korrelaatioille laskettiin myös p-arvo kuvaamaan sen tilastollista merkitsevyyttä (Liitteet 1–7). Selitysasteiden avulla voidaan verrata eri kasvien mallien kykyä selittää riippuvuutta keskenään. RMSE:n laskukaavassa on käytetty ennustettuja arvoja (\hat{y}_i), jotka on saatu laskettua regressioyhtälöistä. RMSE kuvastaa multispektri- ja RGB-kameran datoista tuotettujen mallien virhettä. Edellä mainittujen ominaisuuksien laskemiseen käytettiin MS Exceliä. Liitteissä 1–7 on esitettyinä kaikki kasvustosta lasketut arvot.

$$\text{Pearsonin korrelaatio} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (4)$$

$$\text{Selitysaste} = \left(\frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \right)^2 \quad (5)$$

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (6)$$

, jossa

n on havaintojen lukumäärä

x_i on itsenäinen muuttuja (esim. NDVI indeksin arvo)


y_i on riippuvainen muuttuja (esim. härkäpavun biomassa)

\bar{y} ja \bar{x} ovat muuttujien x_i ja y_i keskiarvot


\hat{y}_i on muuttujan y_i ennustettu arvo, joka on laskettu regressioyhtälön avulla

4.7 Kasvukausi ja kuvausolosuhteet

Tutkimuksen aikainen kesä oli hyvin kuiva ja sademäärä jäi hyvin pieneksi (Kuva 15). Ensimmäiset sateet tulivat vasta kesäkuussa eikä kokonaissadanta ylittänyt 200 mm kasvien kasvukauden aikana (Kuva 15). Vuorokauden keskilämpötila oli alle 30 astetta ja lämmin kausi oli heinäkuun alkupuolelta elokuun alkupuolelle (Kuva 16). Hyvin kuiva kesä viivästytti kasvien kasvuun lähtöä. Sen lisäksi kasvit jäivät mataliksi ja koeruutujen kasvipeitteisyys oli epätasaista (Haarala 2020). Koeruuduissa esiintyi myös rikkakasveja kuten peltomataraa (*Asperula arvensis*). Tuhohyönteiset ja jänikset olivat tuhonneet osan koeruutujen kasvustoa. Rapsilla rapsikuoriainen (*Meligethes aeneus*) oli aiheuttanut tuhoja ja jänikset olivat syöneet ohrakasvuston satoa. Pellavan siemen osoittautuivat viallisiksi ja se ei itänyt.



Kuva 15. Kesän 2018 kumulatiivinen sademäärä Haltialan kentällä mitattuna kahdessa paikassa. Koealueen lähellä olevalla Helsinki-Vantaan lentokentällä vuosien 1980–2010 keskimääräinen sadesumma touko-elokuussa oli 245 mm (Pirinen 2012). Vuonna 2018 siellä mitattiin touko-elokuun sadesummaksi 185 mm (Ilmatieteen laitos 2020).




Kuva 16. Vuorokauden keskilämpötila kesän 2018 ajalta. Helsinki-Vantaan lentoasemalla 30-vuoden keskimääräinen lämpötila touko-, kesä-, heinä- ja elokuussa oli 10,4, 14,6, 17,7 ja 15,8 °C (Pirinen 2012). Vuonna 2018 touko-, kesä-, heinä- ja elokuun vuorokauden keskilämpötila oli 15,3, 15,8, 21,2 ja 18,2 °C (Ilmatieteen laitos 2020).


Koeruuduilla ilmeni myös kesän aikana hieman ilkivaltaa. Koeruutujen reunat oli merkattu sinisillä tikkuilla. Kyseisiä tikkuja oli siirretty ja revitty irti maasta. Tämä on voinut osittain aiheuttaa hieman virhettä laskettaessa koeruutujen tilavuuksia. Tikkujen siirtelyn ei kuitenkaan vaikuttanut näytteidenottopaikkojen löytämiseen multispektrikuvista, koska niiden merkitsemiseen käytettiin muovinpalasia, joiden paikat vaihtelivat riippuen kuvauspäivästä.

4.8 Auringon säteilyn voimakkuus

PYR ja PAR antureiden mittaustulosten mukaan auringon säteilyn voimakkuus vaihteli kesän aikana (Kuvat 17 ja 18). PAR säteilyn osalta säteily oli melko voimakasta heinäkuun alkupuolelta elokuun alkupuolelle (Kuva 17), jolloin koealueella oli lämpimin ajanjakso. PYR säteily oli hyvin pientä heinäkuun aikana (Kuva 18). Antureiden ensimmäinen kokonainen mittauspäivä oli 18.5.2018. Viimeiset biomassat kerättiin hampusta ja rapsista 27.8.2018.



Kuva 17. PAR anturin mittaama auringon säteily kasvukaudella 2018. Pylväs kuvaa vuorokauden keksimääräistä säteilyn voimakkuutta.



Kuva 18. PYR anturin mittaama auringon säteily kasvukaudella 2018. Pylväs kuvaa vuorokauden keksimääräistä säteilyn voimakkuutta.


5. Tulokset

Tässä kappaleessa esitetään tutkimuksen vuoden 2018 tulokset dronejen kuvauksista ja kasvustosta tehdyistä mittauksista. Selvitin tässä työssä multispektrikameran heijastusarvojen ja kasvien kuiva-ainemassojen, klorofyllipitoisuuksien ja lehtialaindeksiarvojen välisiä riippuvuuksia. Tutkin myös 3D-mallien tilavuuksien ja kasvuston kuiva-ainemassojen sekä lehtialaindeksin arvojen välistä riippuvuutta. Koeruuduilta mitattiin lisäksi lämpötila, sademäärä sekä auringon säteilyn voimakkuutta kasvukauden aikana.


5.1 Multispektrikameran heijastus- ja indeksikartat

Käyttämällä Pix4D sovellusta multispektrikameran ottamat kuvat yhdistettiin ortomosaiikkikuviksi ja luotiin koealueesta heijastuskarttoja. Karttojen väritys perustuu heijastetun säteilyn määrään. Kuvissa 19–24 esitetään heijastuskarttoja, joiden kuvat otettiin kaksi päivää ennen rapsin ja hampun viidennen biomassanäytteiden keruuta.


Rapsi oli kehitysasteeltaan 82 BBCH-asteikon perusteella (Taulukko 5) (Hack ym. 1992). Mittausten mukaan eri koeruutujen heijastusarvot vaihtelivat havaittavasti. Sinisen, vihreän ja punaisen värin heijastusarvoista erottuvat muovinpalaset (Kuvassa 19–21 olevat vaaleat pisteet), joiden avulla tunnistettiin rapsin ja hampun koeruudet (Kuvat 19–21). Kartoissa sinisen, vihreän ja punaisen valon aallonpituusalueiden heijastusarvot olivat alle 0,1 kaikissa koeruuduissa. Sen sijaan NIR säteilyn heijastusarvot olivat suurempia kuin sinisen, vihreän, punaisen ja red edge säteilyn alueella (Kuva 22). Red edgen heijastuskartta oli tasainen eri koeruutujen välillä (Kuva 23). NDVI –indeksin kartassa erottui selkeästi kesantuodut, sillä niiden indeksiarvo oli selvästi pienempi kuin kasvustollisissa ruuduissa (Kuva 24). Heijastusarvot kertovat kasvuston sisäisestä vaihtelusta koeruutujen sisällä ja niiden välillä.




Kuva 19. Sinisen värin aallonpituuden heijastuskartta 27.8.2018, jolloin määritettiin hampun ja rapsin viides biomassa. Rapsin kasvuvaihe oli 82 BBCH asteikolla. Kartoissa on käytetty Thermal väritystä. Tällöin vaaleampi väri kuvastaa kasvuston suurempaa heijastavuutta. Hampun ja rapsin sijainti kuvassa 6.




Kuva 20. Vihreän värin aallonpituuden heijastuskartta 27.8.2018, jolloin määritettiin hampun ja rapsin viides biomassa. Rapsin kasvuvaihe oli 82 BBCH asteikolla. Kartoissa on käytetty Thermal väritystä. Tällöin vaaleampi väri kuvastaa kasvuston suurempaa heijastavuutta. Hampun ja rapsin sijainti kuvassa 6.




Kuva 21. Punaisen värin aallonpituuden heijastuskartta 27.8.2018, jolloin määritettiin hampun ja rapsin viides biomassa. Rapsin kasvuvaihe oli 82 BBCH asteikolla. Kartoissa on käytetty Thermal väritystä. Tällöin vaaleampi väri kuvastaa kasvuston suurempaa heijastavuutta. Hampun ja rapsin sijainti kuvassa 6.



Kuva 22. NIR aallonpituuden heijastuskartta 27.8.2018, jolloin määritettiin hampun ja rapsin viides biomassa. Rapsin kasvuvaihe oli 82 BBCH asteikolla. Kartoissa on käytetty Thermal väritystä. Tällöin vaaleampi väri kuvastaa kasvuston suurempaa heijastavuutta. Hampun ja rapsin sijainti kuvassa 6.



Kuva 23. Red edge aallonpituuden heijastuskartta 27.8.2018, jolloin määritettiin hampun ja rapsin viides biomassa. Rapsin kasvuvaihe oli 82 BBCH asteikolla. Kartoissa on käytetty Thermal väritystä. Tällöin vaaleampi väri kuvastaa kasvuston suurempaa heijastavuutta. Hampun ja rapsin sijainti kuvassa 6.



Kuva 24. NDVI indeksikartta 27.8.2018, jolloin määritettiin hampun ja rapsin viides biomassa. Rapsin kasvuvaihe oli 82 BBCH asteikolla. Kartoissa on käytetty


Thermal väritystä. Tällöin vaaleampi väri kuvastaa kasvuston suurempaa indeksiarvoa. Hampun ja rapsin sijainti kuvassa 6.

5.2 Heijastusarvojen ja kasvuston välinen korrelaatio

Seuraavien kappaleiden kuvissa esitetään, miten multispektrikameran heijastusarvot ja niistä lasketut indeksit korreloivat kasvustosta mitattujen LAI:n, lehtivihreäpitoisuuden ja biomassojen kanssa. Haaralan (2020) tutkimuksessa on esitettyä LAI:n, lehtivihreäpitoisuuden ja biomassojen mittaustulokset kasvukauden ajalta.


5.2.1 Kasvustonäytteiden ja heijastusarvojen välinen korrelaatio

Tarkasteltaessa kaikkien koekasvien kuiva-ainemassojen ja heijastusarvojen välisen lineaarisen riippuvuuden selityssasteita voidaan todeta, että ne olivat hyvin pieniä (Kuva 25). Kasvien kehityssasteet olivat taulukon 5 mukaiset. Näytekohtaisesti kerätyn aineiston perusteella laskettaessa korkein selityssaste oli NDVI -indeksin ja kevätvehnän kuiva-ainemassa välillä ($R^2 = 0,31$). Lehtivihreän ja NDVI:n välillä oli suurin selityssaste verrattuna muihin aallonpituusalueisiin ($R^2=0,46$) (Kuva 26).



Kuva 25. Kokeessa viljelyjen kasvien kuiva-ainemassan ja eri valon aallonpituusalueiden (sininen–Rededge) ja NDVI -indeksin välisen riippuvuuden selityssaste (R^2). Laskettu yksittäisten kasvustonäytteiden perusteella. Rapsien ja hampun näytteet kerättiin 29.8 ja kuvat otettiin 27.8. Kauran, vehnän ja härkäpavun näytteet kerättiin 7.8 ja kuvat otettiin 7.8. Liitteessä 1 laskettuna aineistosta RMSE ja


Pearsonin korrelaatio. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N).




Kuva 26. Kokeessa viljelyjen kasvien lehtivihreän ja eri valon aallonpituusalueiden (sininen–Rededge) ja NDVI -indeksin välisen riippuvuuden selitysaste (R^2). Laskettu yksittäisten kasvustonäytteiden perusteella. Rapsien ja hampun näytteet keräti 29.8 ja kuvat oteti 27.8. Kauran, vehnän ja härkäpavun näytteet kerätty 7.8 ja kuvat otettu 7.8. Liitteessä 2 laskettu aineistosta RMSE ja Pearsonin korrelaatio. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N).

5.2.2 Koko koeruudun ja heijastusarvojen välinen korrelaatio

Tarkasteltaessa koko koeruudun heijastusarvoja, olivat riippuvuuden selitysasteet korkeampia kuiva-ainemassan osalta (Kuva 27) kuin yksittäisten näytteiden kohdalla (Kuva 25). Voimakkain riippuvuus oli kuiva-ainemassan ja NDVI:n välillä ($R^2 = 0,77$) (Kuva 27). Lehtivihreäpitoisuuden ja NDVI:n välisen lineaarisen riippuvuuden selitysaste oli myös hyvä ($R^2 = 0,83$) (Kuva 28). Lehtialaindeksin suurimmat selitysasteet löytyivät NDVI:sta ($R^2 = 0,85$) ja NIR aallonpituusalueelta ($R^2 = 0,82$) (Kuvat 29).




Kuva 27. Kokeessa viljelyjen kasvien kuiva-ainemassan ja eri valon aallonpituusalueiden (sininen–Rededge) ja NDVI -indeksien välisen riippuvuuden selitysaste (R^2). Laskettu koko koeruudun aineistosta. Rapsien ja hampun näytteet kerättiin 29.8 ja kuvat otettiin 27.8. Kauran, vehnän ja härkäpavun näytteet kerättiin 7.8 ja kuvat otettiin 7.8. Liitteessä 3 laskettu aineistosta RMSE ja Pearsonin korrelaatio. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N).



Kuva 28. Kokeessa viljelyjen kasvien lehtivihreäpitoisuuden ja eri valon aallonpituusalueiden (sininen–Rededge) ja NDVI -indeksin välisen riippuvuuden selitysaste (R^2). Laskettu koko koeruudun aineistosta. Rapsien ja hampun näytteet


kerättiin 29.8 ja kuvat otettiin 27.8. Kauran, vehnän ja härkäpavun näytteet kerättiin 7.8 ja kuvat otettiin 7.8. Liitteessä 4 laskettu aineistosta RMSE ja Pearsonin korrelaatio. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N).




Kuva 29. Kokeessa viljelyjen kasvien lehtialaindeksien ja eri valon aallonpituusalueiden (sininen–Rededge) ja NDVI -indeksin välisen riippuvuuden selitysaste (R^2). Laskettu koko koeruudun aineistosta. Rapsien ja hampun näytteet kerättiin 29.8 ja kuvat otettiin 27.8. Kauran, vehnän ja härkäpavun näytteet kerättiin 7.8 ja kuvat otettiin 7.8. Liitteessä 5 laskettu aineistosta RMSE ja Pearsonin korrelaatio. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N).

Kuvassa 30 on härkäpapakasvuston lehtialaindeksin ja NDVI:n välinen riippuvuus, jonka selitysaste oli määritetyistä riippuvuuksista korkein. Kuvassa 31 on vuorostaan esitetty NDVI indeksin ja LAI:n välisen heikoin (pienin selitysaste) riippuvuus. Se määritettiin lannoittamattomasta rapsikasvustosta. Luettaessa koko koeruudun heijastusarvoja olivat niiden ja kasvustomittausten välinen riippuvuus voimakkaampi (korkea selitysaste) kuin käyttämällä laskuissa yksittäisten näytteiden heijastusarvoja. Liitteissä 1 ja 2 esitetään aineistosta laskettujen riipu-

vuuksien selitysteiden numerolliset arvot luettaessa heijastusarvoja yksittäisiltä näytteenottopaikoilta. Liitteissä 2, 3 ja 4 on esitetty numerolliset arvot selitysteille luettaessa koko koeruutujen heijastusarvoja.




Kuva 30. Härkäpapukasvustosta (kasvi 2) mitatun lehtialaindeksin ja NDVI -indeksin välinen riippuvuus. Härkäpavun mittaukset suoritettiin 7.8.



Kuva 31. Lannoittamattomasta rapsista (kasvi 7) mitatun lehtialaindeksin ja NDVI -indeksin välinen riippuvuus. Rapsin mittaukset suoritettiin 27.8.


5.3 3D-mallinnus

Kuvassa 32 esitetään koeruuduista otettujen biomassanäytteiden ja 3D-mallista laskettujen tilavuuksien väliset riippuvuudet kasvikohtaisesti. Kuiva-ainemassojen ja 3D-mallien tilavuuksien välisen riippuvuuden korkein selitysaste oli kauralla ($R^2=0,91$) (Kuva 32). Matalin selitysaste oli rapsilla ($R^2=0,49$) (Kuva 32). 3D-mallien tilavuuksien ja kentällä kasvaneiden kasvien biomassojen keskimääräinen selitysaste oli 0,69.




Kuva 32. Koeruutujen kasvustojen 3D-malleista laskettujen tilavuuksien ja koeruuduista kerättyjen kasvien kuiva-ainemassojen välisten riippuvuuden selitysasteet (R^2). Hampun ja rapsin näytteet kerättiin 15.7, 30.7, 13.8 ja 27.8. Härkäpavun, kauran ja vehnän näytteet kerättiin 9.7, 23.7 ja 7.8. Liitteessä 6 on laskettu aineistosta RMSE ja Pearsonin korrelaatio. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N).

Kasvustosta mitattujen LAI arvojen ja 3D-mallien tilavuuksien pohjalta laskettiin niiden välisen lineaarisen riippuvuuden selitysasteita (Kuva 33). Korkein selitysaste oli 0,90 kasvilla 9 (Kaura, ei N) ja huonoin selitysaste oli 0,16 kasvilla 5 (rapsi). Lehtialaindeksin ja 3D-mallin tilavuuden välisen riippuvuuden keskimääräinen selitysaste oli 0,57.




Kuva 33. Koeruutujen kasvustojen 3D-malleista laskettujen tilavuuksien ja koeruuduista mitattujen LAI -arvojen välisten riippuvuuden selitysasteet (R^2). Hampun ja rapsin näytteet kerättiin 15.7, 30.7, 13.8 ja 27.8. Härkäpavun, kauran ja vehnän näytteet kerättiin 9.7, 23.7 ja 7.8. Liitteessä 7 on laskettu aineistosta RMSE ja Pearsonin korrelaatio. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N).

Kuvassa 34 esitetään kauran lehtialaindeksin ja 3D-mallin ilmaiseman tilavuuden välinen riippuvuus, joka oli korkein aineistosta laskettu. Kuvassa 35 on vuorostaan pienin selitysaste, joka oli rapsin lehtialaindeksin ja 3D-mallin tilavuuksien välillä 0,16. Liitteissä 6 ja 7 esitetään 3D-mallien tilavuuksien tarkemmat selitysasteet.



Kuva 34. Kaurasta (kasvi 9, 0 kg N) mitattujen lehtialaindeksien ja 3D-mallin tilavuuksien välinen riippuvuus. 3D-mallien tiedot on kerätty useammalta mittauspäivältä taulukon 5 mukaan.



Kuva 35. Rapsista (kasvi 5, 90 kg N) mitattujen lehtialaindeksien ja 3D-mallin tilavuuksien välinen riippuvuus. 3D-mallien tiedot on kerätty useammalta mittauspäivältä taulukon 5 mukaan.

6. Tulosten tarkastelu

Tässä osiossa verrataan tämän tutkimuksen tuloksia kirjallisuudessa julkaistuihin tuloksiin. Samalla pohditaan, mitkä tekijät mahdollisesti aiheuttivat eroja tuloksissa.

6.1 Kasvuston tunnistaminen multispektrikuvista

Multispektrikameran heijastuskartoista voitiin värityksen perusteella erottaa kasvustoja toisistaan. Esimerkiksi tarkasteltaessa punaisen värin heijastuskarttoja hampun ja härkäpavun kasvuston koeruudut olivat tummempia muihin verrattuna. Tämä tarkoitti, että ne heijastivat vähemmän punaisen värin säteilyä. Sen sijaan NIR ja red edgen alueella hampun ja rapsin heijastusarvot olivat korkeammat kuin muilla koeruuduilla. Kesantokoeruuduilla oli tummempi väritys kuin kasvustollisilla ruuduilla NIR säteilyn heijastuskartassa, mikä tarkoitti pienempiä heijastusarvoja kasvustottomasta maasta. NDVI:n indeksikartassa rapsin, härkäpavun ja hamppu indeksiarvot olivat korkeammat kuin vehnän ja kauran. Kaikilla mitatuilla aallonpituuksilla kasveja ei voitu erottaa toisistaan. Vihreän ja sinisen värin kartoissa kasvusto olivat hyvin samalaisia, sillä niiden heijastusarvot olivat saman suuruisia.

Torres-Sánchez ym. (2013) tutkimuksessa käytettiin multispektri- ja RGB-kameraa rikkakasvien erottamiseen auringonkukkien kasvustosta. Tutkimuksessa käytettiin kolmea eri kasvillisuusindeksiä maaperän, rikkakasvien ja auringonkukkien erottamiseen toisistaan. Indeksit olivat NGRDI, ExG ja NDVI. NGRDI:n ja ExG:n avulla voitiin erottaa rikkakasvit auringonkukista. Multispektrikuvien avulla laskettu NGRDI indeksi sai auringonkukilla arvoja 0,06–0,23 välillä ja rikkakasveilla 0,05–0,03 välillä. RGB-kuvista lasketun ExG:n arvot olivat auringonkukilla 0,17–0,26 ja rikkakasveilla 0,12–0,17. Erilaisilla kasvillisuusindekseillä ja aallonpituusalueilla voidaan erottaa kasveja toisistaan.

6.2 Kasvuston biomassan arviointi dronekuvien perusteella

Multispektrikameralla saatiin hyvin vaihtelevia tuloksia eri kasvien ja aallonpituusalueiden/indeksien kanssa. Korkein selitysaste määritettiin NDVI-indeksin ja vehnän kuiva-ainemassan välisessä riippuvuudessa ($R^2 = 0,77$). Keskimääräinen se-

lityssaste kasvien kuiva-ainemassojen sekä kasvustosta mitattujen aallonpituusalueiden/indeksien välillä oli alhainen (0,15). 3D-malleilla kuiva-ainemassan ja mallilla lasketun tilavuuden välinen riippuvuus oli voimakkaampi kuin multispektrikameran kuvista tehdyissä määrittelyissä. Tämän tutkimuksen voimakkain riippuvuus kasvuston kuiva-ainemassan ja 3D-mallilla määritetyn kasvuston tilavuuden välillä määritettiin kauralla (selityssaste 0,91). 3D-mallien keskimääräinen selityssaste kasvuston kuiva-ainemassoja arvioitaessa oli 0,69.

Monissa tutkimuksissa on hyödynnetty hyperspektrikameraa heijastusarvojen mittaamiseen (Näsi ym. 2018, Viljanen ym. 2018). Näsin ym. (2018) tutkimuksessa kuvattiin ohrapeltoa hyperspektrikameralla. Ohran kuiva-ainemassojen ja hyperspektrikameran heijastusarvojen välisen riippuvuuden selityssasteet olivat 0,78–0,89 välillä. Näsin tutkimuksessa käytettiin koneoppimista (Random forest-menetelmää) heijastusarvojen ja indeksien jälkikäsitteilyssä. Menetelmä käyttää useamman aallonpituusalueiden ja indeksien arvoja kuiva-ainemassojen arvioimiseksi. Tämä on todennäköisesti nostanut heijastusarvojen ja kuiva-ainemassojen välisen riippuvuuden selityssastetta verrattuna omassa tutkimuksessani regressioanalyysillä määritettyihin selityssasteisiin. Näsin ym. (2018) tutkimuksessa laskettiin RGB-kameran kuvista määritettyjen väriarvojen sekä niistä laskettujen indeksien ja ohran kuiva-ainemassan väliseksi selityssasteeksi 0,83. Tämä oli samaa suuruusluokkaa kuin omassa tutkimuksessani 3D-mallilla määritetyn tilavuuden ja kasvuston kuiva-ainemassan välille määritettiin.

Viljasen ym. (2018) tutkimuksessa käytettiin multilineaarista regressiota ja koneoppimista (Random forest-menetelmä) hyperspektrikameran heijastusarvojen käsitteilyssä. Tutkimuksessa saatiin nurmikasvuston kuiva-ainemassan ja kasvilisuuksien väliseksi selityssasteeksi 0,92 multilineaarisella regressiolla ja koneoppimis menetelmällä. Tämä on huomattavasti korkeampi selityssaste kuin mitä tässä tutkimuksessa saatiin käytettäessä tulosten analysoimiseen lineaarista regressioanalyysiä.

Walterin ym. (2018) tutkimuksessa käytettiin pelkästään 3D-malleja vehnän maanpäällisten biomassojen arvioimiseen. 3D-mallin tilavuuksien ja vehnän maanpäällisten biomassojen välisen riippuvuuden selityssaste oli 0,79. Tämä vastasi oman tutkimukseni tulosta. Tutkimuksessani 3D-mallien ja kevätvehnän biomassojen välisen riippuvuuden selityssasteeksi määritettiin 0,63.

Muiden tutkimuksien omaa tutkimustani korkeampiin selitystasoihin kuvaustulosten ja kasvuston kuiva-ainemassan riippuvuuden välillä saattoi vaikuttaa kuvauksissa käytetty kamera. Näsin ym. (2018) ja Viljasen ym. (2018) tutkimuksissa käytettiin hyperspektrikameraa, jossa oli enemmän tutkittavia alueita kuin multispektrikamerassa. Muissa tutkimuksissa hyödynnettiin myös laskentamenetelmiä, jotka ottivat huomioon usean aallonpituusalueen samanaikaisesti. Tällaisia menetelmiä olivat multilineaarinen regressio ja koneoppimiseen pohjautuvaa Random forest- menetelmä. Tässä tutkimuksessa keskityttiin yksittäisten alueiden ja kasvillisuusindeksien hyödyntämiseen lineaarisessa regressiossa. Laskumenetelmät, jotka hyödyntävät useamman alueen mittauksia ovat todennäköisesti tarkempia menetelmiä määrittämään kasvuston ominaisuuksia. Yhdistämällä 3D-mallien korkeustietoja hyperspektrikameran heijastusarvoihin voidaan todennäköisesti saada vielä tarkempia malleja riippuvuuksien määrittämisen (Näsi ym. 2018, Viljanen ym. 2018).

Tämän tutkimuksen alhaisiin multispektrikameran heijastusarvojen ja kasvien biomassojen välisiin selitystasoihin vaikutti todennäköisesti kuivan maaperän aiheuttama häiriö. Mittauskesä oli erittäin kuiva ja kasvusto jäi pieneksi ja epätaaiseksi. Tällöin kasvuston ollessa harvaa on kuiva maaperä vaikuttanut kasvuston heijastusarvoihin. Tutkimuksessa käytetyn multispektrikameran aallonpituusalueet olivat 475, 560, 668, 717 ja 840 nm, jotka vastaavat sinistä, vihreää, punaista, red edge ja lähi-infrapuna aluetta (Micasense 2015). Microimage:n (2012) tulosten mukaan kuivan maan sinisen, vihreän ja punaisen aallonpituusalueen takaisin heijastuvan säteilyn määrä oli noin 15–20 %. Kasvillisuuden heijastusarvoiksi mitattiin hieman alle 5 %. Red edge (717 nm) säteilyn takaisinheijastuminen oli paljaalla maalla hieman yli 25 % ja kasveilla noin 10 %. NIR säteilylle (840 nm) maan heijastusprosentti oli yli 30 %, kun taas kasvillisuuden heijastusarvo oli noin 50 %. Eli tiivistettynä maa heijasti enemmän sinisen, vihreän, punaisen ja red edgen alueella olevaa säteilyä kuin kasvusto. Kasvillisuus heijastaa vuorostaan enemmän NIR säteilyä kuin maaperä. Märän maan heijastusarvot olivat pienemmät kuin kuivalla maalla (Weidong ym. 2001).

Yksittäisten biomassojen paikkojen määrittäminen multispektrikameran kuvista oli hyvin haastavaa. Lennettäessä 50 metrissä yksi kuvan pikseli vastaa 3,4 cm maanpinnalla (Micasense 2017). Täten yksittäisten biomassojen tarkkuudessa

oli virhettä, joka vaikutti edelleen heijastusarvoihin. Luettaessa yksittäisiä biomassanäytteitä on kuvankäsittelyohjelmalla voinut lukea myös rivien välistä kylvöriivien ohella. Tämä todennäköisesti aiheutti häiriöitä kasvuston heijastusarvoihin.

6.3 Kasvuston LAI ja lehtivihreäpitoisuuden arviointi dronekuvien perusteella

Multispektrikameralla saatiin vaihtelevia tuloksia eri aallonpituusalueilla ja niistä lasketuilla indekseillä. Lehtialaindeksin korkein selitysaste määritettiin NDVI:llä ($R^2 = 0,85$). Lehtialaindeksin keskimääräinen selitysaste oli 0,21. Lehtivihreäpitoisuuden ja NDVI:n välisen riippuvuuden korkein selitysaste oli 0,83. Lehtivihreäpitoisuuden keskimääräinen selitysaste oli 0,14. 3D-malleista laskettujen tilavuuksien ja LAI mittauksien välinen selitysaste oli korkeimmillaan 0,90. 3D-mallien ja LAI:n keskimääräinen selitysaste oli vuorostaan 0,57.

Wu ym. (2008) tutkimuksessa oli määritetty maissin lehtivihreäpitoisuutta hyperspektrikameran datojen avulla. Hyperspektrikameran heijastusarvoista laskettiin kasvillisuusindeksejä, joiden avulla pyrittiin arvioimaan kasvien lehtivihreäpitoisuutta. Maissin lehtivihreäpitoisuuden ja TCARI/OSAVI indeksin välisen riippuvuuden selitysasteeksi saatiin 0,68. MCARI/OSAVI indeksin ja maissin lehtivihreäpitoisuuden väliseksi selitysasteeksi saatiin vuorostaan 0,76.

Kanning ym. (2018) tutkimuksessa oli myös käytetty hyperspektrikameraa kuvattaessa vehnäkasvustoa. Hyperspektrikameran heijastusarvojen ja LAI mittauksien välisen riippuvuuden selitysasteeksi saatiin 0,79 ja lehtivihreäpitoisuudelle 0,77.

Tässä tutkimuksessa päästiin multispektrikameran parhaimmilla tuloksilla samoihin suuruusluokkiin muiden tutkimuksien tulosten kanssa lehtialaindeksin ja lehtivihreäpitoisuuden määrittämisessä dronekuvien avulla. Tämän tutkimuksen 3D-mallien avulla tuotettiin kuitenkin parhaat arviot kasvillisuuden lehtialaindeksistä.

6.4 Multispektrikameran ja 3D-mallien vertailu

Verrattaessa tämän tutkimuksen tuloksia keskenään todettiin, että 3D-mallista määritetty kasvuston tilavuus selitti kasvuston kuiva-ainemassaa jonkin verran

paremmin kuin multispektrikameralla kuvista lasketut muuttujat. 3D-mallilla määritetyn kasvuston tilavuuden ja kasvuston kuiva-ainemassan välisen riippuvuuden korkein selitysaste oli 0,91 ja keskimäärin se oli 0,69. Multispektrikameran osalta sama luku oli koko koeruutua luettaessa 0,77 (keskimäärin 0,15) ja 0,31 (keskimäärin 0,053) käytettäessä yksittäisiä biomassanäytteitä. Lehtialaindeksin arvioimisessa korkein selitysaste 3D-malleilla oli 0,9, kun taas multispektrikameralla korkein selitysaste oli 0,85.

Muissa tutkimuksissa hyperspektrikameran tuloksista määritetyt mallit kuvasivat kasvuston biomassaa tarkemmin kuin 3D-mallit. Näsin ym. (2018) tutkimuksessa hyperspektrikameran heijastusarvoilla ja ohran biomassan väliseksi selitysteeksi määritettiin 0,78–0,89. RGB- kuvista luodulla 3D-mallilla riippuvuuden selitysaste oli 0,73. Nurmella vastaavat selitysteet olivat hyperspektrillä 0,52 ja 3D-mallilla 0,01. Viljasen ym. (2018) tutkimuksessa nurmen biomassalle määritettiin hyperspektrikameran heijastusarvoista laskettujen kasvillisuusindeksien avulla selitysteeksi 0,92 ja 3D-mallilla 0,86.

7. Johtopäätökset

Tämän tutkimuksen tulosten perusteella multispektrikameraa ja 3D-malleja voidaan käyttää tiettyjen kasvustojen biomassojen, lehtialan ja lehtivihreäpitoisuuden arvioimiseen. Multispektrikameran heijastusarvojen pohjalta luodut mallit eri kasvien kohdalla eivät ole yhtä tarkkoja kasvien biomassojen arvioimiseen. Yksittäiset indeksit tai aallonpituusalueet eivät välttämättä ole yksinään tarpeeksi tarkkoja kuvaamaan kasvuston biomassoja. Hyödyntämällä tässä käytettyjä monipuolisempia laskentamenetelmiä, jotka käyttävät useampaa aallonpituusaluetta ja kasvillisuusindeksejä, olisi todennäköisesti voitu määrittää tarkempia arvioita kasvuston biomassasta.

Näiden tulosten mukaan 3D-mallien hyödyntäminen kasvuston biomassan ja lehtialan arvioimisessa oli hieman tarkempi menetelmä kuin multispektrikameran mittaamien heijastusarvojen käyttäminen. Käytännön kannalta etuna on, että 3D-mallien tekemiseen riittää tavallinen RGB-kamera, joka on huomattavasti edullisempi vaihtoehto kuin multi- tai hyperspektrikamera. Multispektrikameran kuvien käsittely on kuitenkin selvästi nopeampaa kuin 3D-mallien luominen. Aihe vaatii lisätutkimusta ja menetelmäkehitystä.

Erilaisten virheiden ja häiriöiden poistaminen multispektrikuvista on hankalaa. Kuivat olosuhteet sekä pieni ja epätasainen kasvusto aiheuttavat virheitä heijastuskuvissa, sillä kuivan maan heijastusarvot poikkeavat kasvuston heijastusarvoista. Erilaisten indeksien kehittäminen voisi todennäköisesti vähentää ulkoisten tekijöiden aiheuttamaa häiriötä.

Tämän tutkimuksen perusteella jatkotutkimuksille multispektrikameran hyödyntämiseen eri kasvilajien ominaisuuksien mittaamiseen on tarvetta. Eri kasvien heijastusprosentit poikkeavat hieman toisistaan ja kasvikohtaisten yhtälöiden kehittäminen esimerkiksi biomassan arvioimiseen on tarpeellista. Tehokkuuden parantamiseksi tulee kehittää nykyistä tarkempia malleja multispektrikameran heijastusarvojen käsittelyyn.

8. Kiitokset

Kiitokset Juho Kotalalle dronejen käytön kouluttamisesta ja kuvauksien suunnittelun neuvomisesta. Laura Alakukkoa ja Antti Lajsuta haluan kiittää työn ohjauksesta. Kiitän myös Maatalouskoneiden tutkimussäätiötä, jonka rahoittamassa CropSkills –hankkeessa tutkimus tehtiin.

Lähteet

3DR. Solo. 2020. <https://www.3dr.com/company/about-3dr/solo/>. Viitattu 14.3.2020.

Aasen, H. Burkart, A. Bolten, A. Bareth, G. 2015. Generating 3D hyperspectral information with lightweight UAV snapshot cameras for vegetation monitoring: From camera calibration to quality assurance. ISPRS Journal of Photogrammetry and Remote Sensing. 108: 245–259.

Apogee Instruments. 2006. AccuPAR PAR/LAI Ceptometer Model LP-80 Operator's Manual. http://manuals.decagon.com/Manuals/10242_Accu-par%20LP80_Web.pdf. Viitattu 1.1.2020.

Apogee Instruments. 2019a. Applications and Uses of Pyranometers. <https://www.apogeeinstruments.com/applications-and-uses-of-pyranometers>. Viitattu 11.1.2018.

Apogee Instruments. 2019b. Applications and Uses of Quantum Sensors. <https://www.apogeeinstruments.com/applications-and-uses-of-quantum-sensors>. Viitattu 9.11.2018.

Apogee Instruments. 2019c. Chlorophyll concentration meter. Owner's manual. <https://www.apogeeinstruments.com/content/MC-100-manual.doc>. Viitattu 1.1.2020.

Apogee instruments. 2020. Silicon-cell Pyranometers. <https://www.apogeeinstruments.com/silicon-cell-pyranometers/>. Viitattu 1.1.2020

Bannari A, Morin D, Bonn F. 1995. A Review of Vegetation Indices. Remote Sensing Reviews. 13: 95-120.

- Bendig, J. Yu, K. Aasen, H. Bolten, A. Bennertz, S. Broscheit, J. Gnyp, M. Bareth. G. 2015. Combining UAV-based plant height from crop surface models, visible and near infrared vegetation indices for biomass monitoring in barley. *International Journal of Applied Earth Observation and Geoinformation*. 39: 79-87.
- Carlson, T. Ripley, D. A. 1997. On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sensing of Environment*. 62: 241-252.
- Dash J, Curran P, 2004. The MERIS terrestrial chlorophyll index. *Int. J. Remote Sensing*. 25: 5403–5413.
- Decagon devices. 2014. PAR Photon Flux Sensor. http://manuals.decagon.com/Inserts/13496_PAR%20Photon%20Flux_Print.pdf. Viitattu 1.1.2019.
- DJI. 2020. Phantom 4 advance. <https://www.dji.com/fi/phantom-4-adv>. Viitattu 14.3.2020.
- Droneinfo. 2020. EU dronesäännöt. https://www.droneinfo.fi/fi/eu_dronesaanot. Viitattu 21.4.2020.
- Fitzgerald G. Rodriguez D. O’Leary G. 2010. Measuring and predicting canopy nitrogen nutrition in wheat using a spectral index—The canopy chlorophyll content index (CCCI). *Field Crops Research*. 116: 3. 318-324.
- Gitelson, A. Merzlyak, M. 1994. Quantitative estimation of chlorophyll-a using reflectance spectra: experiments with autumn chestnut and maple leaves. *Journal of Photochemistry and Photobiology, B: Biology*. 22: 247-252.
- Gitelson, A. Merzlyak, M. 1996. Signature analysis of leaf reflectance spectra: algorithm development for remote sensing of chlorophyll. *Journal of plant physiology*. 148: 3-4. 494–500.
- Guo Y, Senthilnath J, Wu W, Zhang X, Zeng Z, Huang H. 2019. Radiometric Calibration for Multispectral Camera of Different Imaging Conditions Mounted on a UAV Platform. *Sustainability*. 11: 978.
- Haarala J. 2020. Härkäpavun jäännöstyypen otto eri viljelykasveilla.

Hack, H., Bleiholder, H., Buhr, L., Meier, U., Schnock-Fricke, U., Weber, E. & Witzemberger, A. 1992. Einheitliche Codierung der Phänologischen Entwicklungsstadien Mono- und Dikotyler Pflanzen. -Erweiterte BBCH-Skala, Allgemein-. Nachrichtenblatt des Deutschen Pflanzenschutzdienstes. 44: 265-270.

Huete A. Justice C. Liu H. 1994. Development of vegetation and soil indices for MODIS-EOS. Remote Sensing of Environment. 49:3. 224-234.

Huete A, 1988. A soil-adjusted vegetation index (SAVI). Remote Sensing of Environment. 25: 3. 295–309.

Ilmatieteen laitos. 2020. Kuukausitilastot. <https://www.ilmatieteenlaitos.fi/kuukausitilastot>. Viitattu 16.3.2020.

Jensen J, Jensen R. 2013. Introductory Geographic Information Systems.

Jhan, J. Rau, J. Haala, N. 2017. Robust and adaptive band-to-band image transform of UAS miniature multi-lens multispectral camera. ISPRS Journal of Photogrammetry and Remote Sensing. 137: 47-60.

Kanning M, Kühling I, Trautz D, Jarmer T. 2018. High-Resolution UAV-Based Hyperspectral Imagery for LAI and Chlorophyll Estimations from Wheat for Yield Prediction. Remote Sensing. 10: 12. 2000.

Kaivosoja J, LUKE. 4.9.2018. Säilörehunurmen sadon määrän kaukokartoitus. https://proagria.fi/sites/default/files/attachment/sailorehunurmen_sadon_maa-ran_kaukokartoitus_jere_kaivosoja_luke.pdf. Viitattu 1.4.2020.

Kaufman Y. Tanre D. 1992. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. IEEE Transactions on Geoscience and Remote Sensing. 30: 2.

Maimaitijiang M, Sagana V, Sidikea P, Hartling S, Esposito F, Fritschid F. 2020. Soybean yield prediction from UAV using multimodal data fusion and deep learning. Remote Snensing of Environment. 237.

Mapir. 2020. Survey3W camera – Visible light RGB. <https://www.mapir.camera/collections/survey3/products/survey3w-camera-visible-light-rgb>. Viitattu 2.3.2020.

MicaSense. 2015. MicaSense RedEdge 3 Multispectral Camera User manual. <https://support.micasense.com/hc/en-us/articles/215261448-RedEdge-User-Manual-PDF-Download->. Viitattu 16.3.2020.

Micasense. 2017. RedEdge: What is the resolution/GSD of the imagers?. <https://support.micasense.com/hc/en-us/articles/226845728-RedEdge-What-is-the-resolution-GSD-of-the-imagers->. Viitattu 3.1.2020.

Micasense. 2018. REDEGE-MX DUAL CAMERA IMAGING SYSTEM. <https://www.micasense.com/s/REMX-Dual-Cam-Brochure.pdf>. Viitattu 25.2.2020.

MicroImages, Inc. 2012. Introduction to hyperspectral imaging. <https://www.microimages.com/documentation/Tutorials/hyprspec.pdf>. Viitattu 29.12.2019.

Mydronelab. 3DR SOLO: THE WORLD'S FIRST SMART DRONE. 2016. <https://www.mydronelab.com/reviews/3dr-solo.html>. Viitattu 14.3.2020.

Näsi, R. Viljanen, N. Kaivosoja, J. Alhonoja, K. Hakala, T. Markelin, L., Honkavaara, E. 2018. Estimating Biomass and Nitrogen Amount of Barley and Grass Using UAV and Aircraft Based Spectral and Photogrammetric 3D Features.

Onset Computer Corporation. 2020. HOBO UA-003-64 Data Logger. <https://www.onsetcomp.com/datasheet/UA-003-64>. Viitattu 12.3.2020.

Peña, J. Torres-Sánchez, J. de Castro, A. Kelly, M. López-Granados. F. 2013. Weed Mapping in Early-Season Maize Fields Using Object-Based Analysis of Unmanned Aerial Vehicle (UAV) Images. International Journal of Applied Earth Observation and Geoinformation. 39: 79–87.

Pirinen, P. Simola, H. Aalto J. Kaukoranta J. Karlsson P. Ruuhela R. 2012. Tilastoja suomen ilmastosta 1981-2010. Ilmatieteenlaitos.

Pix4D. 2017. Pix4Dmapper 4.1 User manual. <https://support.Pix4D.com/hc/en-us/articles/204272989-Offline-Getting-Started-and-Manual-pdf->. Viitattu 16.3.2020.

Pix4D. 2019a. Image acquisition. <https://support.Pix4D.com/hc/en-us/articles/115002471546-Image-acquisition>. Viitattu: 1.1.2020.

Pix4D. 2019b. Radiometric calibration target. <https://support.Pix4D.com/hc/en-us/articles/206494883-Radiometric-calibration-target#label4>. Viitattu 31.12.2019.

Pix4D. 2020. Pix4Dcapture. <https://www.Pix4D.com/product/Pix4Dcapture>. Viitattu 14.3.2020.

Qi J, Chehbouni A, Huete A, Kerr Y, Sorooshian S. 1994. A modified soil adjusted vegetation index. *Remote Sens. Environ.* 48: 119–126.

Rondeaux G, Steven M, Baret F. 1996. Optimization of soil-adjusted vegetation indices. *Remote Sensing of Environment*. 55: 2. 95–107.

Rouse, J.W. 1974. Monitoring Vegetation Systems in the Great Plains with ERTS. Third ERTS Symposium, NASA SP-351, Washington DC, pp. 309–317.

Rusu, R. Marton, Z. Blodow, N. Dolha, M. Beetz, M. 2008. Towards 3D Point cloud based object maps for household environments. *Robotics and Autonomous Systems*. 56: 927-941.

Senop. 2020. Optronics hyperspectral. <https://senop.fi/optronics-hyperspectral>. Viitattu 27.2.2020.

Torres-Sánchez, J, López-Granados F, De Castro A, Peña-Barragán J. 2013. Configuration and Specifications of an unmanned aerial vehicle (UAV) for early site specific weed management. *Plos ONE*, 8: 3.58210

Tucker C. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*. 8:127–150.

Trafi. 2018. OPS M1-32 Kauko-ohjatun ilma-aluksen ja lennokin käyttäminen ilmailuun. https://arkisto.trafi.fi/filebank/a/1543326521/514c2766eb6f8413b2b0d71032cb4337/32598-OPS_M1-32_2018_fi.pdf. Viitattu 1.1.2020.

Viljanen, V. Honkavaara, E. Näsi, R. Hakala, T. Niemeläinen, O. Kaivosoja, J. 2018. Novel Machine Learning Method for Estimating Biomass of Grass Swards Using a Photogrammetric Canopy Height Model, Images and Vegetation Indices Captured by a Drone. *Agriculture*. 8: 70.

- Walter J. Edwards J. McDonald G. Kuche H. 2018. Photogrammetry for the estimation of wheat biomass and harvest index. *Field Crops Research*. 216: 165-174.
- Weidonga L, Bareta F, Xingfaa G, Qingxib T, Lanfenb Z, Bingb Z. 2001. Relating soil surface moisture to reflectance. *Remote Sensing of Environment*. 81: 238–246.
- Woebbecke D, Meyer G, Von Bargen K, Mortensen D. 1995. Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*. 38: 259–269.
- Wu C, Niu Z, Tang Q, Huang W. 2008. Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation. *Agricultural and forest meteorology*. 148: 1230-1241.
- Yara. 2019. Smart farming. <https://www.yara.fi/lannoitus/smartfarming/>. Viitattu 12.1.2019.
- Zadoks, J.C., Chang, T.T. & Konzak, C.F. 1974. A decimal code for the growth stages of cereals. *Weed Research*. 14: 415-421.

Liite 1. Yksittäisten näytteiden heijastusarvojen ja kuiva-ainemassojen aineistosta lasketut tilastoarvot

Kuiva-ainemassa																		
Kasvi	Sininen			Vihreä			Punainen			NIR			Rededge			NDVI		
	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE
2	0,07 (0,66)	0,00	4,99	0,26 (0,07)	0,0	4,83	-0,03 (0,84)	0,00	5,00	0,39 (≤0,05)	0,15	4,61	0,49 (≤0,05)	0,24	4,37	0,25 (0,08)	0,06	4,84
3	-0,21 (0,15)	0,05	12,09	-0,15 (0,32)	0,0	12,24	-0,04 (0,80)	0,00	12,36	0,08 (0,60)	0,01	12,34	-0,01 (0,93)	0,00	12,37	0,09 (0,55)	0,01	12,32
4	-0,41 (≤0,05)	0,17	12,01	-0,31 (≤0,05)	0,1	12,54	-0,47 (≤0,05)	0,22	11,67	0,37 (≤0,05)	0,14	12,24	-0,29 (≤0,05)	0,08	12,64	0,56 (≤0,05)	0,31	10,95
5	0,24 (0,11)	0,06	10,78	0,23 (0,11)	0,0	10,79	0,02 (0,88)	0,00	11,09	0,29 (≤0,05)	0,08	10,63	0,25 (0,09)	0,06	10,76	0,30 (≤0,05)	0,09	10,58
6	0,00 (0,99)	0,00	6,63	0,01 (0,95)	0,0	6,63	0,03 (0,84)	0,00	6,62	-0,05 (0,72)	0,00	6,62	0,03 (0,83)	0,00	6,62	-0,02 (0,87)	0,00	6,62
7	0,12 (0,41)	0,01	17,29	0,15 (0,30)	0,0	17,21	0,20 (0,18)	0,04	17,07	0,18 (0,22)	0,03	17,13	0,20 (0,18)	0,04	17,07	-0,04 (0,78)	0,00	17,40
8	-0,07 (0,66)	0,00	10,78	0,04 (0,81)	0,0	10,79	-0,04 (0,79)	0,00	10,79	0,42 (≤0,05)	0,18	9,78	0,27 (0,07)	0,07	10,40	0,20 (0,17)	0,04	10,58
9	0,11 (0,45)	0,01	9,77	0,11 (0,45)	0,0	9,77	0,19 (0,19)	0,04	9,65	0,00 (0,99)	0,00	9,84	0,16 (0,27)	0,03	9,71	-0,13 (0,39)	0,02	9,76

R on Pearsonin korrelaatiokerroin, R² on selitysaste ja RMSE. Korrelaatiokertoimen alapuolelle on merkitty sulkujen sisäpuolelle p-arvo. Alle 0,05 p-arvot, jotka ovat tilastollisesti merkitseviä on merkattu ≤0.05 merkinnällä. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N). Kasveja 1, 10 ja sr ei ole taulukossa.

Liite 2. Yksittäisten näytteiden heijastusarvojen ja lehtivihreäpitoisuuksien aineistosta lasketut tilastoarvot

Lehtivihreäpitoisuus																		
Kasvi	Sininen			Vihreä			Punainen			NIR			Rededge			NDVI		
	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE
2	-0,21 (0,21)	0,05	58,40	-0,20 (0,24)	0,04	58,55	-0,19 (0,26)	0,04	58,65	0,04 (0,83)	0,00	59,75	-0,16 (0,35)	0,03	59,00	0,21 (0,22)	0,04	58,47
3	-0,30 (0,26)	0,09	77,99	-0,26 (0,33)	0,07	78,90	-0,48 (0,06)	0,23	71,80	0,49 (≤0,05)	0,24	71,16	-0,19 (0,48)	0,04	80,18	0,66 (≤0,05)	0,43	61,38
4	-0,06 (0,75)	0,00	91,15	-0,18 (0,30)	0,03	89,86	-0,23 (0,17)	0,05	88,81	0,03 (0,86)	0,00	91,25	-0,24 (0,16)	0,06	88,66	0,28 (0,10)	0,08	87,71
5	0,16 (0,28)	0,03	70,72	0,13 (0,37)	0,02	70,99	-0,05 (0,72)	0,00	71,52	0,27 (0,06)	0,07	68,99	0,13 (0,38)	0,02	71,01	0,39 (≤0,05)	0,15	65,91
6	-0,21 (0,15)	0,04	46,39	-0,29 (≤0,05)	0,08	45,45	-0,14 (0,36)	0,02	47,02	-0,12 (0,43)	0,01	47,13	-0,19 (0,19)	0,04	46,57	0,01 (0,97)	0,00	47,45
7	0,09 (0,56)	0,01	88,49	0,12 (0,42)	0,01	88,20	-0,12 (0,43)	0,01	88,23	0,19 (0,20)	0,04	87,21	0,04 (0,80)	0,00	88,76	0,42 (≤0,05)	0,17	80,76
8	-0,20 (0,34)	0,04	79,54	0,10 (0,64)	0,01	80,80	-0,47 (≤0,05)	0,22	71,55	0,58 (≤0,05)	0,34	66,18	0,15 (0,48)	0,02	80,27	0,68 (≤0,05)	0,46	59,55
9	-0,18 (0,34)	0,03	153,50	-0,20 (0,27)	0,04	152,70	-0,36 (≤0,05)	0,13	145,41	0,15 (0,41)	0,02	154,19	-0,26 (0,16)	0,07	150,75	0,37 (≤0,05)	0,13	145,15

R on Pearsonin korrelaatiokerroin, R² on selitysaste ja RMSE. Korrelaatiokertoimen alapuolelle on merkitty sulkujen sisäpuolelle p-arvo. Alle 0,05 p-arvot, jotka ovat

tilastollisesti merkitseviä on merkattu ≤ 0.05 merkinnällä. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N). Kasveja 1, 10 ja sr ei ole taulukossa.

Liite 3. Koko koeruudun heijastusarvojen ja kuiva-ainemassojen aineistosta lasketut tilastoarvot

Kasvi	Kuiva-ainemassa																	
	Sininen			Vihreä			Punainen			NIR			RedEdge			NDVI		
	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE
2	-0,46 (0,07)	0,21	2,49	-0,21 (0,43)	0,05	2,74	-0,53 (≤ 0.05)	0,28	2,37	0,54 (≤ 0.05)	0,29	2,37	0,04 (0,88)	0,00	2,81	0,61 (≤ 0.05)	0,38	2,22
3	-0,53 (≤ 0.05)	0,28	6,62	-0,46 (0,07)	0,21	6,93	-0,58 (≤ 0.05)	0,33	6,38	0,22 (0,41)	0,05	7,61	-0,47 (0,07)	0,22	6,91	0,67 (≤ 0.05)	0,45	5,77
4	-0,52 (≤ 0.05)	0,27	8,82	-0,43 (0,09)	0,19	9,29	-0,67 (≤ 0.05)	0,44	7,68	0,56 (≤ 0.05)	0,31	8,58	-0,41 (0,12)	0,17	9,41	0,88 (≤ 0.05)	0,77	4,94
5	0,16 (0,55)	0,03	4,84	0,13 (0,64)	0,02	4,87	0,00 (0,99)	0,00	4,91	0,17 (0,53)	0,03	4,84	0,10 (0,71)	0,01	4,88	0,21 (0,43)	0,04	4,80
6	0,11 (0,69)	0,01	2,81	-0,08 (0,78)	0,01	2,82	0,24 (0,37)	0,06	2,74	-0,18 (0,50)	0,03	2,78	-0,08 (0,78)	0,01	2,82	-0,67 (≤ 0.05)	0,45	2,09
7	0,28 (0,29)	0,08	8,36	0,25 (0,36)	0,06	8,45	0,30 (0,26)	0,09	8,32	0,36 (0,17)	0,13	8,14	0,28 (0,29)	0,08	8,36	0,16 (0,56)	0,03	8,61
8	-0,33 (0,21)	0,11	7,20	-0,22 (0,42)	0,05	7,44	-0,32 (0,23)	0,10	7,24	0,51 (≤ 0.05)	0,26	6,57	-0,09 (0,74)	0,01	7,60	0,45 (0,08)	0,21	6,79
9	0,27 (0,30)	0,08	5,90	0,16 (0,56)	0,02	6,06	0,37 (0,16)	0,14	5,70	-0,13 (0,63)	0,02	6,09	0,16 (0,56)	0,02	6,06	-0,35 (0,18)	0,12	5,75

R on Pearsonin korrelaatiokerroin, R^2 on selitysaste ja RMSE. Korrelaatiokertoimen alapuolelle on merkitty sulkujen sisäpuolelle p-arvo. Alle 0,05 p-arvot, jotka ovat tilastollisesti merkitseviä on merkattu ≤ 0.05 merkinnällä. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N). Kasveja 1, 10 ja sr ei ole taulukossa.

Liite 4. Koko koeruudun heijastusarvojen ja lehtivihreäpitoisuuksien aineistosta lasketut tilastoarvot

Lehtivihreäpitoisuus																		
Kasvi	Sininen			Vihreä			Punainen			NIR			RedEdge			NDVI		
	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE
2	-0,31 (0,33)	0,09	51,33	-0,14 (0,67)	0,02	53,40	-0,32 (0,32)	0,10	51,15	-0,24 (0,45)	0,06	52,35	-0,12 (0,71)	0,01	53,53	0,34 (0,27)	0,12	50,65
3	-0,69 (0,06)	0,48	0,54	-0,60 (0,12)	0,36	0,60	-0,76 (≤0,05)	0,58	0,49	0,40 (0,33)	0,16	0,69	-0,56 (0,15)	0,32	0,62	0,91 (≤0,05)	0,83	0,31
4	0,06 (0,86)	0,00	56,08	-0,08 (0,80)	0,01	55,98	-0,10 (0,75)	0,01	55,87	-0,37 (0,24)	0,13	52,28	-0,24 (0,44)	0,06	54,48	-0,04 (0,90)	0,00	56,12
5	0,21 (0,43)	0,04	51,46	0,18 (0,51)	0,03	51,78	0,04 (0,90)	0,00	52,60	0,23 (0,39)	0,05	51,19	0,15 (0,58)	0,02	52,04	0,27 (0,31)	0,07	50,63
6	-0,04 (0,88)	0,00	21,25	-0,12 (0,65)	0,02	21,10	0,20 (0,46)	0,04	20,84	-0,31 (0,24)	0,10	20,23	-0,14 (0,61)	0,02	21,06	-0,83 (≤0,05)	0,69	11,93
7	0,16 (0,56)	0,02	70,80	0,13 (0,64)	0,02	71,10	-0,05 (0,85)	0,00	71,59	0,05 (0,86)	0,00	71,60	0,03 (0,92)	0,00	71,66	0,38 (0,15)	0,14	66,44
8	0,43 (0,16)	0,19	74,51	0,46 (0,13)	0,21	73,30	0,66 (≤0,05)	0,44	61,86	0,20 (0,53)	0,04	81,05	0,58 (≤0,05)	0,33	67,64	-0,72 (≤0,05)	0,52	57,28
9	-0,24 (0,37)	0,06	153,30	-0,20 (0,45)	0,04	154,59	-0,42 (0,11)	0,17	143,60	0,08 (0,78)	0,01	157,44	-0,30 (0,25)	0,09	150,49	0,39 (0,13)	0,15	145,32

R on Pearsonin korrelaatiokerroin, R² on selitysaste ja RMSE. Korrelaatiokertoimen alapuolelle on merkitty sulkujen sisäpuolelle p-arvo. Alle 0,05 p-arvot, jotka ovat tilastollisesti merkitseviä on merkattu ≤0.05 merkinnällä. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hampu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N). Kasveja 1, 10 ja sr ei ole taulukossa.

Liite 5. Koko koeruudun heijastusarvojen ja lehtialaindeksien aineistosta lasketut tilastoarvot

LAI																		
Kasvi	Sininen			Vihreä			Punainen			NIR			RedEdge			NDVI		
	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE	R	R ²	RMSE
2	-0,66 (≤0,05)	0,43	0,47	-0,47 (0,07)	0,22	0,55	-0,80 (≤0,05)	0,64	0,37	0,91 (≤0,05)	0,82	0,26	-0,13 (0,63)	0,02	0,62	0,92 (≤0,05)	0,85	0,24
3	-0,40 (0,13)	0,16	0,18	-0,34 (0,20)	0,11	0,18	-0,46 (0,07)	0,22	0,17	0,44 (0,09)	0,19	0,17	-0,27 (0,31)	0,07	0,19	0,60 (≤0,05)	0,36	0,15
4	-0,46 (0,07)	0,22	0,26	-0,35 (0,18)	0,12	0,27	-0,50 (≤0,05)	0,25	0,25	0,39 (0,13)	0,15	0,27	-0,30 (0,26)	0,09	0,28	0,64 (≤0,05)	0,41	0,22
5	0,11 (0,69)	0,01	0,18	0,08 (0,78)	0,01	0,18	0,22 (0,41)	0,05	0,18	-0,03 (0,92)	0,00	0,18	0,10 (0,71)	0,01	0,18	-0,52 (≤0,05)	0,27	0,16
6	0,28 (0,30)	0,08	0,32	0,31 (0,24)	0,10	0,32	-0,02 (0,95)	0,00	0,33	0,57 (≤0,05)	0,33	0,27	0,35 (0,19)	0,12	0,31	0,91 (≤0,05)	0,83	0,14
7	0,25 (0,36)	0,06	0,18	0,23 (0,38)	0,06	0,18	0,34 (0,20)	0,12	0,17	0,37 (0,16)	0,14	0,17	0,31 (0,24)	0,10	0,17	0,03 (0,92)	0,00	0,18
8	-0,41 (0,11)	0,17	0,29	-0,31 (0,24)	0,10	0,30	-0,43 (0,10)	0,18	0,29	0,47 (0,07)	0,22	0,28	-0,21 (0,43)	0,05	0,31	0,55 (≤0,05)	0,30	0,27
9	-0,33 (0,21)	0,11	0,13	-0,22 (0,42)	0,05	0,13	-0,52 (≤0,05)	0,27	0,11	0,66 (≤0,05)	0,44	0,10	-0,09 (0,75)	0,01	0,13	0,72 (≤0,05)	0,52	0,09

R on Pearsonin korrelaatiokerroin, R² on selitysaste ja RMSE. Korrelaatiokertoimen alapuolelle on merkitty sulkujen sisäpuolelle p-arvo. Alle 0,05 p-arvot, jotka ovat

tilastollisesti merkitseviä on merkattu ≤ 0.05 merkinnällä. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N). Kasveja 1, 10 ja sr ei ole taulukossa.

Liite 6. 3D-mallien tilavuuden ja kuiva-ainemassojen aineistosta lasketut tilastoarvot

Kasvi	Kuiva-ainemassa							
	2	3	4	5	6	7	8	9
R	0,80 (≤ 0.05)	0,84 (≤ 0.05)	0,79 (≤ 0.05)	0,83 (≤ 0.05)	0,82 (≤ 0.05)	0,70 (≤ 0.05)	0,95 (≤ 0.05)	0,87 (≤ 0.05)
R ²	0,63	0,70	0,63	0,68	0,68	0,49	0,91	0,76
RMSE	3,47	7,70	8,07	7,43	4,43	8,91	3,48	5,74

R on Pearsonin korrelaatiokerroin, R² on selitysaste ja RMSE. Korrelaatiokertoimen alapuolelle on merkitty sulkujen sisäpuolelle p-arvo. Alle 0,05 p-arvot, jotka ovat tilastollisesti merkitseviä on merkattu ≤ 0.05 merkinnällä. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N). Kasveja 1, 10 ja sr ei ole taulukossa.

Liite 7. 3D-mallien tilavuuden ja lehtialaindeksien aineistosta lasketut tilastoarvot.

Kasvi	Lehtialaindeksi							
	2	3	4	5	6	7	8	9
R	0,79 (≤ 0.05)	0,83 (≤ 0.05)	0,93 (≤ 0.05)	0,40 (0,13)	0,52 (≤ 0.05)	0,43 (0,09)	0,94 (≤ 0.05)	0,95 (≤ 0.05)
R ²	0,62	0,69	0,87	0,16	0,27	0,19	0,89	0,90
RMSE	0,47	0,30	0,20	0,51	0,50	0,50	0,21	0,18

R on Pearsonin korrelaatiokerroin, R² on selitysaste ja RMSE. Korrelaatiokertoimen alapuolelle on merkitty sulkujen sisäpuolelle p-arvo. Alle 0,05 p-arvot, jotka ovat tilastollisesti merkitseviä on merkattu ≤ 0.05 merkinnällä. 2 Härkäpapu (20 kg N), 3 Kaura (90 kg N), 4 Kevätvehnä (90 kg N), 5 Rapsi (90 kg N), 6 Hamppu (50 kg N), 7 Rapsi (Ei N), 8 Kaura (50 kg N), 9 Kaura (Ei N). Kasveja 1, 10 ja sr ei ole taulukossa.